



УНИВЕРЗИТЕТ У КРАГУЈЕВЦУ

ФАКУЛТЕТ ИНЖЕЊЕРСКИХ НАУКА
УНИВЕРЗИТЕТА У КРАГУЈЕВЦУ

Тијана И. Шуштершич

**ИМПЛЕМЕНТАЦИЈА АЛГОРИТАМА
ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ У ОБРАДИ
БИОМЕДИЦИНСКИХ СИГНАЛА КАО
ПОДРШКА ОДЛУЧИВАЊУ У
ДИЈАГНОСТИЦИ БОЛЕСТИ КИЧМЕНОГ
СТУБА**

Докторска дисертација

Крагујевац, 2022.



UNIVERSITY OF KRAGUJEVAC

FACULTY OF ENGINEERING
UNIVERSITY OF KRAGUJEVAC

Tijana I. Šušteršič

**IMPLEMENTATION OF ARTIFICIAL
INTELLIGENCE ALGORITHMS IN
BIOMEDICAL SIGNALS PROCESSING TO
SUPPORT DECISION-MAKING IN THE
DIAGNOSIS OF SPINAL DISEASES**

Doctoral Dissertation

Kragujevac, 2022

Аутор
Име и презиме: Тијана Шуштершич
Датум и место рођења: 31.05.1993., Крагујевац
Садашње запослење: Асистент на Факултету инжењерских наука, Универзитета у Крагујевцу
Докторска дисертација
Наслов: Имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба
Број страница: 163
Број слика: 73
Број библиографских података: 179
Установа и место где је рад израђен: Факултет инжењерских наука, Универзитета у Крагујевцу
Научна област (УДК): 004.8:004.932.72
Коментори: др Весна Ранковић, редовни професор, Факултет инжењерских наука, Универзитета у Крагујевцу - коментор др Ненад Филиповић, редовни професор, Факултет инжењерских наука, Универзитета у Крагујевцу - коментор
Оцена и одбрана
Датум пријаве теме: 09.03.2020. год.
Број одлуке и датум прихватања теме докторске/уметничке дисертације: IV-04-596/19 од 09.09.2020. год.
Комисија за оцену научне заснованости теме и испуњености услова кандидата: 1. Др Весна Ранковић, редовни професор, Факултет инжењерских наука Универзитета у Крагујевцу 2. др Ненад Филиповић, редовни професор, Факултет инжењерских наука Универзитета у Крагујевцу 3. Др Владимир Миловановић, доцент, Факултет инжењерских наука Универзитета у Крагујевцу 4. Др Лукас Расулић, ванредни професор, Медицински факултет, Универзитет у Београду 5. Др Војин Ковачевић, доцент, Факултет медицинских наука, Универзитет у Крагујевцу
Комисија за оцену и одбрану докторске/уметничке дисертације: 1. Др Велибор Исаиловић, ванредни професор, Факултет инжењерских наука Универзитета у Крагујевцу, 2. Др Владимир Миловановић, ванредни професор, Факултет инжењерских наука Универзитета у Крагујевцу, 3. Др Дубравко Ђулибрк, редовни професор, Факултет техничких наука, Универзитет у Новом Саду, 4. Др Лукас Расулић, редовни професор, Медицински факултет, Универзитет у Београду. 5. Др Војин Ковачевић, доцент, Факултет медицинских наука, Универзитет у Крагујевцу.
Датум одбране дисертације:

Захвалница

Велику захвалност дугујем коментору проф. др Весни Ранковић, редовном професору Факултета инжењерских наука у Крагујевцу, на стручној помоћи, конструктивним сугестијама, уложеном труду и времену. Захваљујем јој се на личном залагању и на саветима који су унапредили ову докторску дисертацију.

Посебно се захваљујем коментору др Ненаду Филиповићу, редовном професору Факултета инжењерских наука у Крагујевцу, на усмеравању током израде докторске дисертације и који ми је пружио прилику да се бавим истраживањима у области биоинжењеринга у оквиру Истраживачко-развојног центра за биоинжењеринг у Крагујевцу.

Захваљујем се такође на прилици да будем део пројеката ОИ-174028, билатералних пројеката, пројеката финансираних у оквиру COST програма, Horizont2020 (SGABU (бр. 952603), SILICOFCM (бр. 777204), PANBIORA (бр. 760921)) и CEI пројекта COVIDAI (бр. 305.6019-20) у оквиру којих сам имала прилику да учим, путујем и размењујем искуства са колегама из света, као и за финансирање током целог трајања докторских студија. Захвалност дугујем и Програму Националних стипендија L'Oréal – UNESCO „За жене у науци“ чији сам добитник за 2021. годину, који је подржао моја истраживања у области вештачке интелигенције.

Посебну захвалност дугујем др Александру Пеулићу, редовном професору Географског факултета, Универзитета у Београду, на покретању идеје о анализи сигнала кичменог стуба, развоју мерне платформе, помоћи у раду на ФПГА чиповима, као и дивној сарадњи током свих година истраживања. Захваљујем се и др Миодрагу Пеулићу из Центра за неурохирургију Клиничког центра Крагујевац, на прикупљању испитаника за мерење на конструисаној платформи и сарадњи током година истраживања и обраде сигнала мерења. Такође, дугујем велику захвалност др Војину Ковачевићу, из Центра за неурохирургију Клиничког центра Крагујевац, на уступљеним подацима у облику слика са магнетне резонанце, који су служили као основа за примену алгоритама вештачке интелигенције.

Захвална сам свим члановима комисије на корисним примедбама и предлозима, који су квалитет докторске дисертације подigli на виши ниво.

Хвала колегама из Центра за биоинжењеринг, Факултета инжењерских наука, Универзитета у Крагујевцу на колегијалности и подршци приликом израде докторске дисертације.

На крају, велику захвалност дугујем својој породици, посебно мајци Вањи, на безграничној љубави, подршци и разумевању током целог школовања.

Крагујевац 2022. године

Тијана Шуштершич

Резиме

Лумбални болни синдром се сматра једним од водећих јавно-здравствених проблема и представља узрок дуготрајних боловања и изостанка радно-активне популације с посла. Први стадијум у многим врстама дегенеративних болести кичменог стуба је дегенерација интервертебралног диска. Ове промене могу довести до дискус херније која се дефинише као локализовани пролапс материјала диска ван граница простора интервертебралног диска. Поред неспорно огромног здравственог проблема, лумбална дискус хернија представља и социјално-економски проблем који значајно оптерећује здравствени и социјални буџет држава, услед издвајања средстава за медицинске трошкове и исплату надокнада за боловања.

Савремена медицина се суочава са изазовом анализирања велике количине података, неопходних за решавање сложених клиничких проблема. Примена вештачке интелигенције се показала као потенцијално решење за обраду медицинских сигнала, јер је карактерише способност откривања значајних и скривених веза у скупу података. Стога она налази велику примену у клиничкој дијагностици, лечењу и предвиђању развоја и исхода болести. На основу постојеће литературе, може се закључити да се вештачка интелигенција све више користи у истраживањима проблема везаних за обољења кичменог стуба, а посебно у анализи медицинских снимака са магнетне резонанце или рендгена.

У овој докторској дисертацији је представљена нова методологија која се заснива на развоју и имплементацији алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба. Циљ је био да се развије систем за подршку одлучивању који ће помоћи лекарима како у погледу тачности успостављања дијагнозе, тако и по питању брзине доношења одлуке. Са једне стране, анализирани су снимци са магнетне резонанце и предложен је аутоматизовани приступ у дијагностици херније лумбалног диска коришћењем МРИ слика у аксијалној и сагиталној равни. Скуп података је представљао комбиновни скуп из јавно досупне базе, али и локално прикупљених слика у Клиничком центру Крагујевац. Предложена методологија се састојала од неколико корака који су укључивали сегментацију интервертебралног диска, издвајање региона од интереса и побољшање контраста, након чега су примењене најсавременије методе дубоког учења у виду конволуционих неуронских мрежа за класификацију дискус херније у одговарајуће класе (здрава, испупчена, централна, десна или лева хернија за аксијалну раван и здрав, L4/L5, L5/S1 ниво херније у сагиталној равни). С друге стране, анализирани су сигнали ослањања снимљени мерном платформом, који је требало да ухвати феномен слабости мишића стопала, који потиче од притиска нерва у кичменом каналу услед херније. На снимљеним сигнаlima примењени су различити класификациони алгоритми (логистичка регресија, стабло одлучивања, случајне шуме, наивни Бајес, метода потпорних вектора, K најближих суседа), заједно са различитим методама нормализације, у сврху дијагностиковања дискус херније на нивоима L4/L5 или L5/S1, на левој или десној страни или детектовања здраве особе без херније. Добијени резултати

показују да неки нелинеарни класификатори показују бољу тачност у односу на друге класификаторе.

У дисертацији је извршено поређење добијених резултата модела са златним стандардом, дефинисаним кроз експертско мишљење, односно дијагнозу лекара, са експерименталним мерењима, као и са резултатима из литературе. Сви модели су постигли тачност која је већа у односу на постојеће резултате најновијих истраживања, а представљају и напредак у односу на аспект сложености проблема истраживања (вишекласна класификација у две равни). Главна предност примењене методологије и дизајнираног система је стварање јединственог и неинвазивног система који омогућава специфичну дијагностику болести ван болнице, смањујући време чекања и обезбеђујући систем подршке лекарима у доношењу одлука. Инспирирани имплементацијом алгоритама на хардверу, такође је тестирана примена неких алгоритама на реконфигурабилним платформама попут ФПГА чипова, који су показали задовољавајуће резултате, како за преоперативну дијагностику, тако и при детекцији побољшања након операције и физикалне терапије. Такође, нумеричке симулације расподеле померања и напона за дискове код здраве особе и особе са дискус хернијом показале су јасне разлике, које могу да представљају индикацију лекару за преписивање адекватне терапије. Даљи рад на развоју истраживаних модела могао би да води до њихове примене у претклиничкој и клиничкој пракси, а наставак истраживања је усмерен на примену методологије и за друге болести кичменог стуба, као и спрезање алгоритама вештачке интелигенције и нумеричких симулација.

Кључне речи: дискус хернија, вештачка интелигенција, анализа биомедицинских сигнала, конволуционе неуронске мреже, класификација, нумеричке симулације

Abstract

Lumbar pain syndrome is considered one of the leading public health problems and is the cause of long-term illness and absence of the working population from work. The first stage in many types of spinal degenerative diseases is degeneration of the intervertebral disc. These changes can lead to disc herniation that is defined as localized prolapse of disc material outside the intervertebral disc space. In addition to the indisputably huge health problem, lumbar disc herniation is also a socio-economic problem that significantly burdens the health and social budget of the state, due to allocations for medical expenses and sickness leave payment.

Modern medicine faces the challenges of analyzing a large amount of data (so called big data), necessary to solve complex clinical problems. Artificial intelligence has emerged as a potential solution for processing such medical signals, because it is characterized by the ability to detect significant and hidden patterns in a data set. Therefore, it is widely used in clinical diagnosis, treatment and prediction of disease development and disease outcome. Based on the existing literature, artificial intelligence has drawn attention that it can be widely used in the research of spinal problems, especially in the analysis of medical images from magnetic resonance or X-rays.

This doctoral dissertation develops a new methodology based on the development and implementation of artificial intelligence algorithms in the biomedical signal processing to support decision - making in the diagnosis of spinal diseases. The goal was to develop a decision support system that will help doctors both in terms of the accuracy of the diagnosis and in terms of the speed of decision-making. On one hand, magnetic resonance (MR) images were analyzed and an automated approach in the diagnosis of lumbar disc herniation using MR images in the axial and sagittal planes was proposed. The data set was a combined set from a publicly available database, but also locally collected scans at the Clinical Center Kragujevac. The proposed methodology consisted of several steps that included segmentation of the intervertebral disc, cropping of regions of interest and improving contrast, followed by the use of state-of-the-art deep learning methods in the form of convolutional neural networks to classify disc hernia into appropriate classes (healthy, bulge, central, right or left hernia for axial view and healthy, L4 / L5, L5 / S1 hernia level in sagittal view). On the other hand, the signals from foot forces recorded by the measuring platform were analyzed, which were supposed to capture the phenomenon of weakness of the foot muscles, which originates from the pressure of the nerve in the spinal canal due to herniation. Various classification algorithms (logistic regression, decision tree, random forests, naïve Bayes, support vector machine, K-nearest neighbors) were applied on the recorded signals, together with different normalization methods, for the purpose of diagnosing disc herniation at L4 / L5 or L5 / levels on the left or right side or detecting a healthy person without herniation. The obtained results imply that some nonlinear classifiers show better accuracy compared to other classifiers.

In both parts of the dissertation, a comparison of the obtained results with the gold standard, defined through expert opinion, i.e. doctor's diagnosis, with experimental measurements, as well as with the results from the literature is performed. All models have achieved an accuracy that is higher than the accuracy of state-of-the-art results, and the results in this dissertation also represent an advancement in the field taking into

consideration the complexity of the system (multi-class classification using two views). The main advantage of the applied methodology and the designed system is the creation of a unique and non-invasive tool that can achieve diagnosis of discus hernia disease outside the hospital, reducing waiting times, queues for imaging and serving as a decision support system for doctors. Inspired by the implementation of algorithms on hardware, the application of some algorithms on reconfigurable platforms such as FPGA chips was also tested, which showed satisfactory results for both preoperative diagnostics and detected improvements after surgery and physical therapy. Additionally, numerical simulations of the displacement and stress distribution for lumbar discs in a healthy person and a person with a disc herniation have shown clear differences, which may be an indication to the doctor to prescribe adequate therapy. Further work in direction of the development of these models could lead to their application in preclinical and clinical practice, and the continuation of research is focused on the application of methodology for other spinal diseases, as well as coupling artificial intelligence algorithms and numerical simulations.

Keywords: disc herniation, artificial intelligence, biomedical signal analysis, convolutional neural networks, classification, numerical simulations

САДРЖАЈ

1. УВОДНА РАЗМАТРАЊА.....	1
1.1. Предмет докторске дисертације.....	2
1.2. Основне полазне хипотезе.....	3
1.3. Допринос дисертације.....	4
1.4. Организациона структура дисертације.....	5
2. АНАТОМИЈА КИЧМЕНОГ СТУБА И ПРОЦЕС ДЕГЕНЕРАЦИЈЕ ДИСКОВА	7
2.1. Дегенерација диска.....	10
2.2. Методе дијагностиковања и третирања хернијације диска.....	12
2.2.1. Методе дијагностиковања хернијације диска.....	12
2.2.2. Методе третирања хернијације диска.....	14
3. ПРЕГЛЕД ДОСАДАШЊИХ ИСТРАЖИВАЊА	15
3.1. Досадашња истраживања у обради MRI снимака кичменог стуба.....	15
3.2. Досадашња истраживања у обради биомедицинских сигнала ослањања.....	19
3.3. Досадашња истраживања у имплементацији алгоритама на ФПГА чипу.....	21
4. РАЗВОЈ МЕТОДОЛОГИЈЕ ЗА ОБРАДУ БИОМЕДИЦИНСКИХ СИГНАЛА У ДИЈАГНОСТИЦИ БОЛЕСТИ КИЧМЕНОГ СТУБА.....	24
4.1. Конволуционе неуронске мреже.....	24
4.1.1. Архитектуре често коришћених конволуционих неуронских мрежа.....	29
4.2. Аутоматска детекција и класификација диск херније на сликама магнетне резонанце.....	34
4.2.1. Сегментација региона од интереса (РОИ).....	35
4.2.2. Исецање региона од интереса.....	40
4.2.3. Побољшање контраста региона од интереса и аугментација података....	41
4.2.4. Издвајање карактеристичних обележја	42
4.2.5. Класификација	43
4.2.6. Мапе активације класа.....	44
4.2.7. Коришћени сет података.....	46
4.2.8. Статистичке метрике за евалуацију.....	46
4.3. Алгоритми за класификацију 1Д биомедицинских сигнала	48
4.4. Методологија за аутоматску анализу биомедицинских сигнала ослањања	53
4.4.1. Систем за мерење и поступак снимања	53
4.4.2. Класификација дискус херније на основу снимљених сигнала	57
4.4.3. Коришћени сет података.....	60
5. РЕЗУЛТАТИ АНАЛИЗЕ И КРЕИРАЊЕ СИСТЕМА ЗА ПОДРШКУ ОДЛУЧИВАЊУ ..	62

5.1. Резултати аутоматске детекције и класификације диск херније на сликама магнетне резонанце	62
5.1.1. Резултати сегментације	62
5.1.2. Резултати издвајања карактеристика	67
5.1.3. Резултати класификације	68
5.1.4. Мапе активације класа.....	73
5.2. Резултати анализе биомедицинских сигнала ослањања.....	74
5.2.1. Резултати класификације	74
5.2.2. Креирање система за подршку одлучивању.....	81
6. ИМПЛЕМЕНТАЦИЈА АЛГОРИТАМА ЗА ДИЈАГНОЗУ ДИСКУС ХЕРНИЈЕ НА ФПГА ЧИПУ	85
6.1. Имплементација Наивног Бајеса алгорита на ФПГА чипу.....	87
6.1.1. Алгоритам Наивног Бајеса за софтверску имплементацију.....	88
6.1.2. Методологија имплементације Наивног Бајеса на ФПГА чипу.....	90
6.1.3. Резултати имплементације Наивног Бајеса на ФПГА чипу.....	91
6.2. Имплементација фази логике на ФПГА чипу.....	96
6.2.1. ФПГА имплементација фази логике за дијагностику диск херније	96
6.2.2. Фази теорија – кораци у дизајну система закључивања.....	97
6.2.3. Анализа сигнала применом фази логике на ФПГА чипу	99
6.2.4. Коришћени сет података.....	103
6.2.5. Резултати имплементације фази логике на ФПГА чипу.....	104
7. НУМЕРИЧКА АНАЛИЗА ОПТЕРЕЂЕЊА ИНТЕРВЕРТЕБРАЛНОГ ДИСКА.....	109
7.1. Материјални модели кичмених пршљенова и дискова	112
7.2. Задата оптеређења.....	115
7.3. Тип анализе.....	116
7.4. Резултати анализе методом коначних елемената.....	119
7.5. Спрезање компјутерског моделирања и машинског учења	122
8. ЗАКЉУЧНА РАЗМАТРАЊА.....	124
ЛИТЕРАТУРА	127
ПРИЛОЗИ	140
Прилог 1 - Статистичке мере сензитивности, специфичности и прецизности	140

СПИСАК КОРИШЋЕНИХ СКРАЋЕНИЦА

ASIC - Application-Specific Integrated Circuit

BS - Batch Size

CAM - Class Activation Maps

CDF - Centroid Distance Function

CLAHE - Contrast Limited Adaptive Histogram Equalization

CNN - Convolutional Neural Networks

CT - Computed Tomography

DCNN - Deep Convolutional Neural Network

DICOM - Digital Imaging and Communications in Medicine

DSP - Digital Signal Processor

ELU - Exponential Linear Unit

ЕМГ – електромиографија

EP – Epoch

FEM - Finite Element Method

FIS - Fuzzy Inference System

FN - False Negative

FP - False Positive

FPGA - Field-Programmable Gate Array

GAP - Global Average Pooling

GPU – Graphical Processing Unit

GRAD-CAM - Gradient Weighted Class Activation Mapping

GVF - Gradient Vector Flow

HSV - Hue, Saturation, Value

HOG - Histogram of directed Gradients

ILSVRC - ImageNet Large-Scale Visual Recognition Challenge

IP - Intellectual Property

K-NN – K-Nearest Neighbors

LR - Learning Rate

LReLU - Leaky ReLU

MLP - Multi-Layer Perceptron

MRI - Magnetic Resonance Imaging

PR - Precision Recall

ReLU - Rectified Linear Unit

ROC - Receiver Operating Characteristic Curve

ROI - Region of Interest

RTL - Register-Transfer Level

SReLU - S-Shaped ReLU

SVM - Support Vector Method

TN - True Negative

TNR - True Negative Rate

TP - True Positive

TPR - True Positive Rate

VHDL - VHSIC hardware description language

СПИСАК ИЛУСТРАЦИЈА

Слика 2.1 Структура кичменог стуба (прилагођено на основу (Lumen 2022)).....	7
Слика 2.2 Лумбални пршљен поглед са стране и одозго.....	8
Слика 2.3 Шематски приказ мапа дерматома доњих удова	9
Слика 2.4 Поређење нормалних и хернираних дискова	10
Слика 2.5 Поређење различитих ступњева дискус херније (а) протрузија (б) пролапс (ц) екструзија (д) секвестрација	11
Слика 4.1 Пример конволуционе неуронске мреже	25
Слика 4.2 Пример конволуције.....	26
Слика 4.3 Различите активационе функције	26
Слика 4.4 Сажимање максимумом	27
Слика 4.5 Сажимање усредњавањем	27
Слика 4.6 Архитектура AlexNet мреже.....	30
Слика 4.7 Архитектура VGG мреже	31
Слика 4.8 Архитектура GoogleNet мреже.....	32
Слика 4.9 Модул започињања	33
Слика 4.10 Регуларни блок (лево) и резидуални блок (десно).....	33
Слика 4.11 Архитектура ResNet-18 мреже	34
Слика 4.12. Предложени концепт методологије успостављања дијагнозе диск херније.....	35
Слика 4.13. Архитектура U-net мреже.....	36
Слика 4.14 Први корак у контракционој путањи	36
Слика 4.15 Процес конволуције и сажимања максимумом поновљен 3 пута.....	37
Слика 4.16 Дно коришћене U-net мреже.....	37
Слика 4.17 Први део путање експанзије.....	38
Слика 4.18 Транспонована конволуција, конкатенација и конволуција се понављају три пута.....	38
Слика 4.19 Последњи корак на експанзионом путу пре креирања предвиђене маске.....	38
Слика 4.20 U-net архитектура у облику прилагођеном за имплементацију	39
Слика 4.21 Поступак аугментације слике (а) оригинална слика; (б) хоризонтално пресликана слика; (в) слика са побољшаном осветљеношћу	42
Слика 4.22 Израчунавање функције удаљености од тежишта а) методологија за израчунавање функције, б) пример растојања за диск без херније, в) пример растојања за диск са хернијом	43
Слика 4.23 Процес генерисања мапе активације класа (адаптирано на основу (Zhou, et al. 2016))	45
Слика 4.24 Логистичка регресија (адаптирано на основу (Suthaharan 2016)).....	48
Слика 4.25 Стабло одлучивања (адаптирно на основу (Tang, Alelyani and Liu 2014))	49
Слика 4.26 Класификатор случајне шуме (адаптирно на основу (Tang, Alelyani and Liu 2014)).....	50
Слика 4.27 Пример методе потпорних вектора на дводимензионом простору.....	51

Слика 4.28 Класификатор К најближих суседа (адаптирно на основу (Tang, Alelyani and Liu 2014))	52
Слика 4.29 Поређење положаја сензора у истраживању (Yan et al.) (Yan and Ming 2010) (лево) и у оквиру докторске дисертације (десно).....	54
Слика 4.30 Општи преглед структуре мерног система	54
Слика 4.31 Мерни систем – шематски приказ постављања сензора на платформу	55
Слика 4.32 Дисплеј мерења здраве особе	56
Слика 4.33 Шематски приказ развијене методологије за дијагностику дискус херније.....	57
Слика 4.34 Пример тросегментног снимања са јасно означеним областима нормалног стајања, стајања на прстима и стајања на пети.....	58
Слика 5.1 Функција губитка током тренинга и валидације.....	64
Слика 5.2 Коефицијент Дајс током тренинга и валидације	64
Слика 5.3 Јакардов коефицијент сличности током тренинга и валидације.....	65
Слика 5.4 Оригинална слика (лево), ручно сегментирани диск (у средини) и аутоматски сегментирани диск (десно) за оптимизоване хиперпараметре ЕП = 35, БС = 8 и ЛР = 0.01 на сликама у аксијалној равни.....	66
Слика 5.5 Оригинална слика (лево), ручно сегментирани диск (у средини) и аутоматски сегментирани диск (десно) за оптимизоване хиперпараметре ЕП = 35, БС = 8 и ЛР = 0.01 на сликама у сагиталној равни.....	66
Слика 5.6 Резултати функције удаљености од тежишта диска за а) здрав диск, б) диск хернију.....	68
Слика 5.7 Функција губитка за тренинг и валидациони скуп а) аксијална раван, б) сагитална раван.....	69
Слика 5.8 Функција тачности за тренинг и валидациони скуп а) аксијална раван, б) сагитална раван	69
Слика 5.9 Конфузиона матрица а) аксијална раван, б) сагитална раван	70
Слика 5.10 РОК крива а) аксијална раван, б) сагитална раван.....	71
Слика 5.11 ПР крива а) аксијална раван, б) сагитална раван.....	72
Слика 5.12 Мапе активације класа за.....	74
Слика 5.13 Визуелизовани примери стабала одлучивања – приказани резултати без нормализације и нормализацијом range	78
Слика 6.1 Шематски приказ креираног система за дијагностику дискус херније .	88
Слика 6.2 Шематски дијаграм тока за дијагностику диск херније на ФПГА	91
Слика 6.3 Резултати симулације имплементираног експертског система са приказаним свим главним сигнаlima.....	92
Слика 6.4 Резултати описаног експертског система за дијагностику дискус херније имплементираног на ФПГА.....	92
Слика 6.5 Блок дијаграм предложеног спрегнутог ФПГА система за обраду сигнала и платформе за мерење силе стопала.....	96
Слика 6.6 Лингвистичке варијабле које се користе у процесу фазификације за дијагностику дискус херније	98
Слика 6.7 RTL шема топ_модула за систем дијагнозе расплинуте диск херније...100	
Слика 6.8 RTL шема У1 подсистема за фазификацију улазних података.....	101

Слика 6.9 RTL шема У2 подсистема за комбинацију улазних фазификованих података.....	101
Слика 6.10 RTL шема У3 подсистема за кодирање улазних података	102
Слика 6.11 RTL шема У4 подсистема за коначну одлуку (дефазификација).....	103
Слика 6.12 Резултати симулације у случају Л5/С1 дискус херније са десне стране	104
Слика 7.1 Предложена методологија за реконструкцију лумбалног дела кичменог стуба.....	110
Слика 7.2 Површинска мрежа модела Л3-Л5 пршљена са интевертебралним дисковима код особе без дискус херније.....	111
Слика 7.3 Површинска мрежа модела Л3-Л5 пршљена са интевертебралним дисковима код особе са дискус хернијом.....	111
Слика 7.4 Поређење ефективних померања здравог (лево) и хернираног (десно) Л4/Л5 лумбалног диска	119
Слика 7.5 Детаљан приказ ефективних померања здравог Л4/Л5 лумбалног диска у више погледа	120
Слика 7.6 Детаљан приказ ефективних померања хернираног лумбалног диска у више погледа.....	120
Слика 7.7 Померања здравог Л4/Л5 диска у х правцу (а) и у правцу (б).....	121
Слика 7.8 Померања хернираног Л4/Л5 диска у х правцу (а) и у правцу (б)	121
Слика 7.9 Повезаност бола услед укљештења нерва као последица дискус херније (лево) и нумеричка симулација хернираног диска (десно).....	122

СПИСАК ТАБЕЛА

Табела 4.1. Опис коришћеног сета података са бројем слика по равни и типу херније.....	46
Табела 4.2 Оправданост имплементираних алгоритама	59
Табела 4.3 Демографске карактеристике испитаника – здраве особе и испитаници са дијагнозом лумбалне диск херније.....	61
Табела 5.1 Статистичке мере за тренинг, валидацију и тест подскуп у процесу сегментације коришћењем оптимизованих вредности ЕП = 35, БС = 8, и ЛР = 0.0165	
Табела 5.2 Поређење постигнутих резултата са резултатима из литературе.....	67
Табела 5.3 Разлике у обележјима за аксијалне слике (средња вредност ± стандардна девијација)	67
Табела 5.4 Тачност по класама за дијагностику диск херније (аксијални и сагитални поглед)	70
Табела 5.5 Прецизност и одзив за дијагностику диск херније (аксијална и сагитална раван)	71
Табела 5.6 Просечни (усредњени) резултати класификације за само аксијалну раван, само сагитална раван и обе равни истовремено	72
Табела 5.7 Преглед литературних резултата код анализе сличних проблема.....	73
Табела 5.8 Резултати имплементираних класификатора са различитим методама нормализације на подацима када су 32 пацијента коришћена за обуку и 1 пацијент је коришћен у сврху тестирања	75
Табела 5.9 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 31 пацијент коришћен за обуку и 2 пацијента у сврху тестирања (тврда тачност).....	75
Табела 5.10 Резултати имплементираних класификатора са различитим методама нормализације на сировим подацима када је 31 пацијент коришћен за обуку и 2 пацијента у сврху тестирања (средња тачност)	76
Табела 5.11 Резултати имплементираних класификатора са различитим методама нормализације на сировим подацима када је 30 пацијената коришћено за обуку и 3 пацијента у сврху тестирања (оштра тачност).....	76
Табела 5.12 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 30 пацијената коришћено за обуку и 3 пацијента у сврху тестирања (средња тачност).....	76
Табела 5.13 Резултати примењених класификатора са различитим методама нормализације на подацима када је 29 пацијената коришћено за обуку и 4 пацијента у сврху тестирања (оштра тачност)	77
Табела 5.14 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 29 пацијената коришћено за обуку и 4 пацијента у сврху тестирања (средња тачност).....	77
Табела 5.15 Резултати тестирања на пост-хируршким субјектима	79
Табела 5.16 Резултати тестирања на испитаницима након физикалне терапије .	80
Табела 5.17 Статистичке мере – осетљивост, специфичност и прецизност за стабло одлучивања са нормализацијом range, у различитим комбинацијама тренинг-тест подскупова.....	82

Табела 6.1 Излазне вероватноће за четири различита пацијента, сваки са различитом дијагнозом (резултати ФПГА симулације).....	93
Табела 6.2 Излазне вероватноће за четири различита пацијента, сваки са различитом дијагнозом (резултати Матлаб симулације).....	93
Табела 6.3 Резултати унакрсне валидације (средња тачност \pm варијанса).....	94
Табела 6.4 Демографски подаци тестираних пацијената - постоперативни и после физикалне терапије.....	103
Табела 6.5. Поређење резултата за преоперациону дијагнозу на основу златног стандарда, резултата добијених коришћењем Матлаб-а и имплементацијом на ФПГА.....	105
Табела 6.6 Поређење резултата са побољшаним стањем након операције на основу златног стандарда, резултата добијених коришћењем Матлаб-а и ФПГА.....	106
Табела 6.7. Поређење резултата за побољшање стања након физикалне терапије на основу златног стандарда, резултата добијених коришћењем Матлаб-а и ФПГА.....	106
Табела 6.8. Резиме коришћења ресурса уређаја.....	107
Табела 7.1 Број чворова и елемената за креиране моделе.....	110
Табела 7.2 Преглед материјалних карактеристика коришћених у моделима кортикалне кости лумбалног пршљена.....	112
Табела 7.3 Преглед материјалних карактеристика коришћених у моделима сунђерасте кости лумбалног пршљена.....	112
Табела 7.4 Преглед материјалних карактеристика коришћених у моделима нуклеуса лумбалног диска.....	113
Табела 7.5 Преглед материјалних карактеристика коришћених у моделима анулуса лумбалног диска.....	114
Табела 7.6 Резиме коришћених материјалних карактеристика.....	115

1. УВОДНА РАЗМАТРАЊА

Лумбални болни синдром представља један од најчесталијих здравствених проблема данашњице. Процењује се да око 80% популације током свог живота бар једном има болове у слабинском делу кичме (Jandrić and Antić 2006). Због тога је тај синдром постао један од водећих јавно-здравствених проблема јер представља најчешћи узрок дуготрајних боловања и изостанка радно-активне популације с посла. Поред неспорно огромног здравственог проблема, лумбална дискус хернија представља и социјално-економски проблем који значајно оптерећује здравствени и социјални буџет држава, услед издвајања средстава за медицинске трошкове и исплату надокнада за боловања. Уколико је неопходна операција, трошкови се знатно повећавају. Наравно, све ово има смисла уколико су шансе за опоравак и помоћ пацијенту добре. Међутим, уколико је дијагноза погрешна, пацијент је без разлога био подвргнут операцији, претрпео је бол, а настали су и одређени финансијских трошкови. Поред тога, могу се појавити и компликације након операције (енгл. *failed back syndrome*) до којих може доћи уколико је дијагноза била нетачна, ако је примењена неадекватна хируршка декомпресија (непрепознавање стенозе латералног рецессуса, латералне хернијације и секвестрираног слободног фрагмента), као последица секундарне нестабилности и дегенеративне промене итд., што може указивати да пацијента није уопште ни требало оперисати.

Савремена медицина се суочава са изазовом анализирања и примене велике количине знања неопходног за решавање сложених клиничких проблема (Mintz and Brodie 2019). Вештачка интелигенција (енгл. *artificial intelligence*) има способност откривања значајних и скривених веза у скупу података и стога налази велику примену у клиничкој дијагностици, лечењу и предвиђању развоја болести. Данас је вештачка интелигенција интегрисана у наш свакодневни живот у многим облицима, као што су лични асистенти (Сири, Алека, Гоогле асистент итд.), аутоматизовани масовни транспорт, авијација и компјутерске игре (Mintz and Brodie 2019). У скорије време, почела је и примена вештачке интелигенције у медицини како би се побољшала брига о пацијентима убрзавањем процеса постављања дијагнозе, као и постизањем веће тачности, отварајући пут ка пружању боље здравствене заштите у целини. Развој медицинске вештачке интелигенције односи се пре свега на развој програма намењених да помогну клиничарима у формулисању дијагнозе, доношењу терапијских одлука и предвиђању исхода (Ramesh, et al. 2004). Ови програми су дизајнирани да помогну здравственим радницима у њиховим свакодневним обавезама, пре свега, у задацима који се односе на манипулацију подацима и знањем. Радиолошки снимци, патолошки узорци и електронски медицински картони пацијената се анализирају коришћењем метода вештачке интелигенције, помажући у процесу постављања дијагнозе и лечењу пацијената, као и креирању система за подршку одлучивању лекару. У бројним истраживањима и студијама медицинске вештачке интелигенције, првенствено се фокус ставља на одрживост и изводљивост да се различите рачунарске технике вештачке интелигенције уграде у моделирање медицинских информација.

Нагли пораст броја објављених радова последњих година сведочи да се вештачка интелигенција све више користи у истраживањима проблема везаних за проблеме са кичмом, посебно при радиолошким снимањима, али и у другим

областима, као што је предвиђање исхода лечења (Galbusera, Casaroli and Bassani 2019). Објављени резултати су обећавајући, нпр. предложене методе вештачке интелигенције омогућавају тачну и поновљиву детекцију кичмених пршљенова на сликама магнетне резонанце. Све ово представља мотивацију за истраживање могућности аутоматске детекције проблема кичменог стуба коришћењем метода вештачке интелигенције.

1.1. Предмет докторске дисертације

Код људи постоји пет лумбалних пршљенова и пет интервертебралних дискова. Интервертебрални дискови, кичмени лигаменти и фасетни зглобови повезују пршљенове, при чему интервертебрални дискови играју улогу зглобова између два суседна тела пршљенова. Диск има две основне функције: физиолошки делује као амортизер и ограничава кретање између суседних пршљенова. Језгро је у стању да апсорбује велике силе, посебно у детињству када садржи висок проценат воде (око 90%) (Fardon, et al. 2014). Међутим, са годинама, постепено долази до дехидрације диска и јавља се тенденција ка дегенерацији и губитку способности преноса и смањењу притиска. Упоредо са дехидратацијом долази до смањења садржаја протеогликана, као и унутрашњег цепања фрагментације језгра са прстеном. Ове промене могу довести до дискус херније, која се дефинише као локализовано померање материјала диска изван граница простора интервертебралног диска (Fardon, et al. 2014). Материјал диска може бити језгро, хрскавица, фрагментована апофизна кост, ануларно ткиво или било која њихова комбинација (Fardon, et al. 2014). Описане дегенеративне промене се брже развијају код особа које се баве физичким активностима, код људи који су изложени дејству вибрација или обављају послове у седећем положају.

Саставни део савремене медицинске дијагностичке праксе представља снимање са циљем да се процени стање пацијента, побољша ефикасност лечења, изврши планирање за евентуалну хируршку интервенцију итд. У те сврхе, као подаци се најчешће користе медицинске слике са магнетне резонанце (енгл. *Magnetic Resonance Imaging - MRI*) или компјутерске томографије (енгл. *Computed Tomography - CT*). Стандардна медицинска процедура, која користи мануелну анотацију региона од интереса од стране доктора експерта, показала је велику варијабилност и лошу поновљивост. Поред тога, неуролошки преглед пацијената са знацима лумбалне радикулопатије је изузетно важан за одређивање нивоа локализације руптуре интервертебралног диска. Зато су веома важни статички и динамички тестови мишићне функције. Ови тестови обухватају преглед плантарне и дорзалне флексије прстију и стопала, а лекар испитује јачину мишића пацијента вршећи притисак на прсте и пете стопала. Овакав вид испитивања је субјективан, а коришћена скала за оцењивање је недовољно осетљива.

Предмет ове докторске дисертације је развој модела вештачке интелигенције за аутоматску детекцију болести кичменог стуба, са нагласком на дискус хернију и њену класификацију. Оригиналност предложене методе лежи у коришћењу дубоког учења, као грани вештачке интелигенције, у аутоматизацији процеса анализе медицинских слика, скраћењу времена за дијагностиковање, као и обезбеђивање велике тачности и поновљивости резултата. Све претходно изложено представља добру основу за развој метода за аутоматску детекцију дискус херније обрадом различитих биомедицинских сигнала (MRI слика, сигнала

очитаних са сензора итд.). Испитивана су два најчешће коришћена модалитета у дијагностици дискус херније – магнетна резонанца и неуролошки преглед пацијената. Када се ради о препознавању образаца на медицинским сликама, тада се најчешће користе дубоке конволуционе неуронске мреже (енгл. *deep convolutional neural networks* - *DCNN*). Са довољно великим сетом података, DCNN може да научи да аутоматски издваја релевантне карактеристике из тренинг узорака за дати задатак итеративним прилагођавањем својих тежинских коефицијената. Поред анализе слика, ради аутоматске детекције и класификације лумбалне дискус херније, у оквиру тезе биће представљен и развој платформе за објективно мерење и одређивање нивоа дискус херније на основу измерених вредности сила ослањања.

Компјутерски систем дијагностике може бити од помоћи за стварање дијагностичких резултата у кратком времену. Уз то, може се повећати прецизност у постављању дијагнозе и могу се елиминисати људске грешке изазване умором и могућим визуелним грешкама радиолога. Овакве методе вештачке интелигенције представљају систем за подршку при одлучивању у постављању тачне дијагнозе лумбалне дискус херније.

1.2. Основне полазне хипотезе

Данас је углавном усвојено мишљење да ако MRI не покаже хернирани диск, усваја се мишљење да дискус хернија не постоји. Међутим, истраживачи су показали да су резултати добијени магнетном резонанцом 30% лажно позитивни. Други су пак, коришћењем наивног Бајесовог класификатора утврдили да је вероватноћа догађаја лумбалне дискус херније, на основу само позитивног налаза MRI-ја била 8% (Trafimow and Trafimow 2016). То говори да је вероватноћа да не постоји лумбална дискус хернија, чак и ако постоји позитиван налаз MRI, 92%. На основу свега напред изнетог, јасно је да се MRI скенирање не може користити као једини извор дијагностичких информација.

Мануелни тест испитивања мишићне снаге код болесника је релативно једноставан за извођење и не захтева никакву специјализовану опрему, што се сматра његовом основном предношћу. Упркос овим предностима, он има и своја ограничења. Бодовање мишићне слабости је субјективно и засновано је на перцепцији испитивача. Постоји такође и значајна варијабилност између пацијената, јер неки испитаници имају већу мишићну снагу од других. Такође, тест не узима у обзир мишићно-скелетна оболења која могу учинити тестирање болним, као што су тендинопатија или артритис. Тест зависи од мотивисаности пацијента, која може бити недовољна код неких пацијената, као нпр. због болова, неразумевања инструкција, психолошких разлога итд. Треба такође нагласити да резултати зависе преважно од искуства лекара, а на субјективне одлуке лекара утичу многи фактори, као што су окружење, емоционално и психофизичко стање особе итд.

У циљу развоја методологије, при анализи коришћених биомедицинских сигнала, уведене су следеће претпоставке:

1. Помоћу алгоритама вештачке интелигенције могуће је са високом тачношћу и са уштедом у времену извршити дијагнозу лумбалне дискус херније.

2. При ослањању стопала (пета и прсти), када је хернија диска присутна на нивоу L4-L5 или L5-S1, нерви трпе притисак, што изазива слабост мишића на одговарајућем делу левог или десног стопала.
3. Креирани систем са платформом и сензорима је у стању да открије побољшање у мишићној снази након операције и физикалне терапије у поређењу са стањем пре операције.
4. Коришћењем ФПГА чипа (енгл. *Field-Programmable Gate Array (FPGA)*) могуће је извршити комуникацију мерне платформе и чипа за анализу и на тај начин креирати портабилни систем за брзу дијагностику дискус херније.
5. Комбинацијом резултата добијених анализом MRI и снимљених вредности силе ослањања могуће је издвојити шаблоне присутних код пацијената са истим типом дискус херније, што ће повећати тачност дијагностике у односу на то када се користи само један модалитет снимања.

1.3. Допринос дисертације

Основни циљ докторске дисертације је развој и имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба. Научни допринос дисертације се огледа се у чињеници да је развијена метода за аутоматску детекцију дискус херније обрадом различитих биомедицинских сигнала (MRI слика, сигнали прочитани са сензора итд.).

Модели који су развијани у оквиру ове дисертације су засновани како на традиционалним класификационим алгоритмима са надгледаним учењем попут К-најближих суседа (енгл. *K - nearest neighbors*), методе потпорних вектора (енгл. *Support Vector Method - SVM*), стабла одлучивања (енгл. *Decision Tree*), методе случајних шума (енгл. *Random Forest*), тако и на методама дубоког учења попут конволуционих неуронских мрежа (енгл. *Convolutional Neural Networks - CNN*). Свака од метода је оптимизована у смислу њених хиперпараметара, а коришћене су и различите методе за евалуације на тренинг, валидационом и тест скупу.

Предност овог приступа огледа се најпре у аутоматизацији и неинвазивности, а затим у објективном дијагностиковању нивоа дискус херније и побољшању мишићне слабости након операције и физикалне терапије. Главна предност је што се применом процесора на бази ФПГА чипа остварује краћа временска анализа у односу на остале тренутно доступне микро-процесоре. Такође, неки аутори оправдавају неопходност коришћења ФПГА чипа при обради медицинских сигнала са креираних уређаја објашњавајући да су нпр. у земљама трећег света попут Индије, лекари ретко доступни у руралним срединама (само 2% лекара живи у руралним срединама) (Chowdhury and Saha 2008). Стога, проблеми слични дијагнози дискус херније захтевају употребу јефтине, преносне опреме, која троши мале количине енергије за рад, обраду сигнала врши великим брзинама и има могућност дијагностике у реалном времену, што у крајњем исходу има за циљ да обезбеди неопходне информације о пацијентима који живе у руралним срединама, и који би уз консултацију са лекарима добили неопходну и адекватну негу. Резултати добијени овом тезом могу наћи велику примену у болницама, јер омогућавају смањење редова за дијагностичка снимања (СТ, MRI итд.) и избегавање зрачења. Компјутерски систем дијагностике омогућава стварање дијагностичких

резултата у кратком временском року. Уз то, може се повећати прецизност дијагностике и могу се елиминисати људске грешке изазване умором и потенцијалним визуелним грешкама радиолога.

1.4. Организациона структура дисертације

Докторска дисертација садржи пре свега уводна разматрања на основу којих је проистекла мотивација за истраживање. У поглављу 1 дефинисани су предмет и циљ дисертације, као и полазне хипотезе. Такође, објашњен је научни допринос дисертације, као и основне предности предложене методологије.

У поглављу 2 објашњена је анатомија лумбалног дела кичменог стуба. Описан је проблем дискус херније лумбосакралне регије, као и узроци који доводе до појаве оваквог проблема, методе дијагностиковања и лечења. Посебна пажња је посвећена методама снимања попут магнетне резонанце, као златног стандарда у дијагностици болести кичменог стуба, али и мануелном мишићном тесту који се користи за детекцију мишићне слабости, а последица је притискања нерава услед херније. Ова два модула детекције су представљали основу и мотивацију кандидата да развије методологију за израду ове докторке дисертације, ради успостављања објективне методе за дијагностику.

У трећем поглављу приказан је преглед литературе са описом претходних истраживања која су имала за тему обраду сигнала за потребе детекције хернијације диска. Ово поглавље је подељено на два дела и то: досадашња истраживања у обради MRI снимака кичменог стуба и досадашња истраживања у обради биомедицинских сигнала ослањања.

У поглављу 4 описана је методологија која је такође подељена на два дела: методологија аутоматске сегментације међупршљенских дискова на основу MRI снимака и класификација нивоа и стране дискус херније и методе класификације нивоа дискус херније на основу издвојених атрибута са мерне плоче. У том поглављу је описан коришћени експериментални мерни систем за мерење силе ослањања, платформа са сензорима, као и комуникација са компјутером.

Следеће поглавље (поглавље 5) даје резултате на основу предложене методологије, са посебним нагласком на резултате већ поменутих двају праваца истраживања. У оквиру аутоматске анализе медицинских слика, резултати су већински засновани на примени конволуционих неуронских мрежа (сегментација и класификација), док у анализи сигнала ослањања, резултати су добијени на основу класификационих алгоритама попут наивног Бајеса, фази логике, стабла одлучивања, логистичке регресије, методе потпорних вектора, методе случајних шума итд. У овом поглављу је извршена и верификација добијених резултата, као и поређење добијених резултата са доступном литературом и стављање добијених резултата у контекст објективне дијагностике.

У поглављу 6 објашњена је примена ФПГА чипа у процесу анализе сигнала силе ослањања ради убрзања извршавања алгоритама, али и концепт креирања портабилне станице која не зависи од оперативног система, перформанси компјутера, дакле извршена је имплементација алгоритама на чипу. Наравно, тачност анализе помоћу ФПГА не сме бити мања у односу на тачност резултата коришћењем софтверских решења.


У поглављу 7 дат је преглед доступних нумеричких модела у области симулација расподеле померања и напона за болести кичменог стуба. Развијена је методологија заснована на методи коначних елемената и приказани су упоредни резултати за дискове код здраве особе и особе са дискус хернијом.

У поглављу 8 дата су закључна разматрања ове дисертације и правци будућих истраживања.

Последње поглавље представља коришћену литературу у изради дисертације.

2. АНАТОМИЈА КИЧМЕНОГ СТУБА И ПРОЦЕС ДЕГЕНЕРАЦИЈЕ ДИСКОВА

Кичма се састоји од 33 пршљена и пружа главни ослонац телу, омогућавајући усправно стајање, савијање и увијање, истовремено штитећи кичмену мождину од повреда. Пршљенови су нумерисани и подељени на регионе: вратни (цервикални) са 7 пршљенова, грудни (торакални) са 12 пршљена, слабински (лумбални) са 5 пршљенова, крсни (сакрални) и тртични (кокцис) (Слика 2.1). Горња 24 пршљена су независне кости повезане зглобовима и лигаментима, док су пршљенови сакрума и кокциса спојени. Пршљенови у сваком региону имају јединствене карактеристике које им помажу да обављају своје главне функције. Када се гледа са стране, кичма одрасле особе има природну кривину у облику латиничног слова С. Вратни и слабински део леђног региона имају благу конкавну кривину, а грудни и крсни региони имају конвексну кривину (Clinic, Spine anatomy 2022).



Слика 2.1 Структура кичменог стуба (прилагођено на основу (Luten 2022))

Снажни мишићи и кости, флексибилне тетиве и лигаменти и осетљиви нерви доприносе здравој кичми. Ипак, било која од ових структура захваћена напрезањем, повредом или болешћу може изазвати бол (Clinic, Spine anatomy 2022). Две главне мишићне групе које утичу на кичму су екстензори и флексори. Мишићи екстензори омогућавају устајање и подизање предмета. Екстензори су причвршћени за задњи део кичме. Мишићи флексори су напред и укључују трбушне мишиће. Ови мишићи омогућавају савијање напред-назад, и важни су у подизању и контроли свода у доњем делу леђа. Леђни мишићи стабилизују кичму. Ситуација као што је нагли покрет може створити велико оптерећење на кичмени стуб и цело тело довести у дисбаланс (Clinic, Spine anatomy 2022).

Цервикални пршљенови (врат) - главна функција вратног дела кичме је да издржи тежину главе. Седам вратних пршљенова су означени бројевима од Ц1 до Ц7. Врат има највећи опсег покрета због два специјализована пршљена која се спајају са лобањом. Први пршљен (Ц1) је атлас у облику прстена који се директно повезује са лобањом. Овај зглоб омогућава климање главом напред-назад. Други пршљен (Ц2) представља осовину у облику клина, која има пројекцију звану

одонтоид, око које се атлас окреће. Овај зглоб омогућава бочно, односно померање главе лево-десно (Clinic, Spine anatomy 2022).

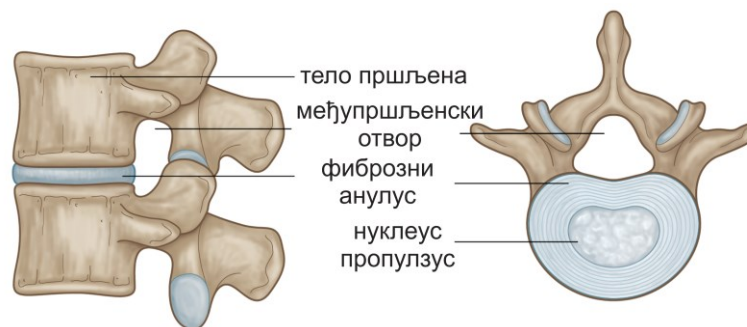
Торакални пршљенови (грудни део леђа) - главна функција торакалног сегмента кичме је да формира са ребрима грудни кош и омогући адекватну функцију срца и плућа. Дванаест торакалних пршљенова су означени бројевима од T1 до T12. Опсег покрета у торакалном делу кичме је ограничен (Clinic, Spine anatomy 2022).

Лумбални пршљенови (слабински део леђа) - главна функција лумбалног дела кичме је да поднесе тежину трупа или горњег дела тела. Пет лумбалних пршљенова су означени бројевима од L1 до L5. Ови пршљенови су много већи како би апсорбовали притисак приликом подизања и ношења тешких предмета (Clinic, Spine anatomy 2022).

Сакрални пршљенови (крсни део леђа) - главна функција сакрума је повезивање кичме са костима карлице (илијачним костима). Постоји пет сакралних пршљенова, који су спојени. Заједно са илијачним костима формирају прстен који се назива карлични појас (Clinic, Spine anatomy 2022).

Регија тртице (кокцис) - четири спојене кости тртице обезбеђују везу за лигаменте и мишиће карличног дна.

Сваки пршљен се састоји од три функционална дела (Clinic, Spine anatomy 2022). Два суседна пршљена кичменог стуба су одвојена интервертебралним диском, који спречава трење између костију и апсорбује дејство сила које делују на кичмени стуб. Дискови се налазе између пршљенова и састоје се од фиброзног анулуса (енгл. *anulus fibrosus*) и нуклеуса пулпозуса (енгл. *nucleus pulposus*). Фиброзни анулус представља спољашњи прстен диска и има фиброзне траке повезане са сваком телом пршљена. Поред прстена, сваки диск има језгро испуњено гелом које се зове нуклеус (Слика 2.2) (Clinic, Spine anatomy 2022).



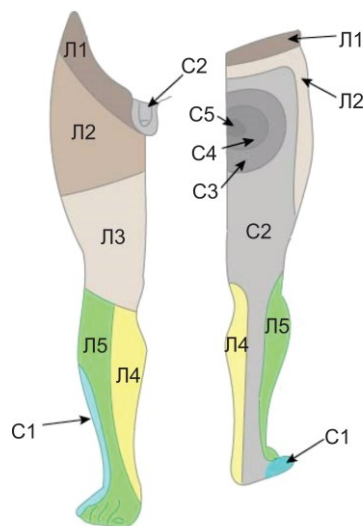
Слика 2.2 Лумбални пршљен поглед са стране и одозго (прилагођено на основу (Clinic, Spine anatomy 2022))

Укрштена влакна анулуса повлаче кости пршљенова заједно насупрот еластичном отпору које креира језгро испуњено гелом. Језгро се понаша као куглични лежај, дозвољавајући телима пршљенова да се котрљају преко нестишљивог гела. Језгро испуњено гелом садржи углавном течност. Ова течност се апсорбује током ноћи док се лежи и избацује се током дана док се врши кретање. Са годинама, дискови све више губе способност да реапсорбују течност и постају крхки и равнији. Такође болести, као што су остеоартритис и остеопороза, узрокују раст коштаних маса и формирање остеофита. Повреда и напрезање могу узроковати испупчење или хернијацију дискова, стање у којем се језгро истискује

кроз прстен и притиска нервне корене, што узрокује бол у леђима (Clinic, Spine anatomy 2022).

Тридесет један пар кичмених нерава грана се од кичмене мождине. Кичмени нерви преносе импулс између тела и кичмене мождине како би контролисали осећај и покрет. Сваки кичмени нерв има два корена. Вентрални (предњи) корен преноси моторичке импулсе из мозга, а дорзални (задњи) корен преноси сензорне импулсе до мозга. Вентрални и дорзални корени се спајају и формирају кичмени нерв, који путује низ кичмени канал, уз мождину, све док не дође до свог излазног отвора - интервертебралног форамена. Када нерв прође кроз интервертебрални форамен, он се грана; свака грана има и моторна и сензорна влакна. Мања грана (названа задњи примарни рамус) окреће се уназад да би снабдевала кожу и мишиће задњег дела тела. Већа грана (названа предњи примарни рамус) се окреће напред како би снабдела кожу и мишиће предњег дела тела и формирала већину главних нерава (Clinic, Spine anatomy 2022). Кичмени нерви су нумерисани према пршљеновима изнад којих излазе из кичменог канала. Осам вратних кичмених нерава су Ц1 до Ц8, 12 торакалних кичмених нерава су Т1 до Т12, 5 лумбалних кичмених нерава су Л1 до Л5, а 5 сакралних кичмених нерава су С1 до С5. Постоји 1 кокцигеални нерв.

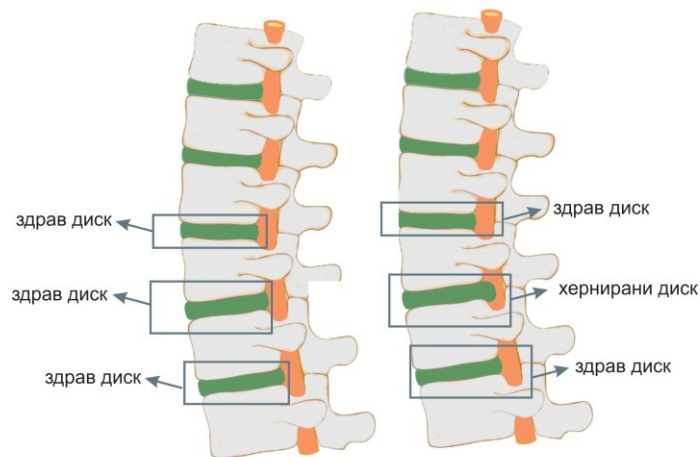
Кичмени нерви инервишу одређена подручја и формирају пругасте шаре преко тела које се назива дерматоми. Један од примера инервације мишића и подручја коже који су присутни на ножним прстима потичу од нерава између Л5 и С1 дискова у кичми, док се инервација пета врши преко нерава који настају између Л4 и Л5 дискова у кичми (Greenberg and Arredondo 2001, Winn 2016). Слика 2.3 приказује шематски мапу дерматома за доње удове. Лекари користе овај образац при постављању дијагнозе и локализације проблема са кичмом на основу подручја бола или слабости мишића. На пример, бол у ногама (ишијас) обично указује на проблем у близини Л4-С3 нерава (Bogduk 2016).



Слика 2.3 Шематски приказ мапа дерматома доњих удова
(прилагођено на основу (Šušteršič, et al. 2019))

2.1. Дегенерација диска

Први корак у многим врстама дегенеративних болести кичме је дегенерација интервертебралног диска. Процес дегенерације диска често се поистовећује са термином хернија диска. Хернија диска настаје када материјал диска продре кроз пукотину у прстену. Ова гел супстанца иритира кичмене нерве, стварајући хемијску и механичку иритацију, што резултира упалом кичменог нерва и отоком изазваним притиском херније диска (Слика 2.4).




Слика 2.4 Поредица нормалних и хернираних дискова

Под хернијацијом подразумевамо локализовани пролапс материјала диска ван граница простора интервертебралног диска. Интервертебрални диск обезбеђује стабилност у миру и распоређује оптерећење кичменог стуба у покрету. Промене које доводе до појаве пролапса диска су десикација, смањење садржаја протеогликана, мукоидна дегенерација и урастање фиброзног ткива. Предиспонирајући фактори настанка лумбалног бола су тешки физички послови повезани са подизањем терета преко двадесет килограма, нарочито професионална употреба тешког алата.

Временом, дискус хернија се може развијати у два правца - може доћи до спонтане регресије дискус херније, када долази до делимичног или потпуног ублажавања бола, али исто тако може изазвати озбиљно оштећење нервног ткива (нерва), што често захтева операцију. Постоје различити стадијуми хернијације (Fardon, et al. 2014, H. Winn 2016) и то:

- испупчен диск (протрузија) – ово стање се дешава када прстен диска остане нетакнут, али формира избочење које може притискати нерве; без руптуре анулуса фиброзе (Слика 2.5а).
- пролапс – то је обично следећи степен у хернијацији где нуклеус пулпосус мигрира до најудаљенијих влакана анулуса фиброзе (Слика 2.5б)
- екструзија – оригинална хернија диска (која се назива и сломљени или склизнути диск) дешава се када постоји прекид континуитета фиброзног анулуса, што доводи до истискивања језгра испуњеног гелом (Слика 2.5в)

- секвестрација – понекад је хернија толико екстремна да постоји слободан фрагмент, што значи да се комадић потпуно откинуо од диска и да мигрира у кичмени канал (Fardon, et al. 2014, Н. Winn 2016) (Слика 2.5г).



Слика 2.5 Поредица различитих ступњева дискус херније (а) протрузија (б) пролапс (ц) екструзија (д) секвестрација

Огромна већина хернираних дискова настаје у лумбалној кичми, где кичмени нерви излазе између лумбалних пршљенова, а затим се поново спајају тако да формирају ишијадични и феморални нерв који пролазе низ предњи/задњи део бутине и ноге (Н. Winn 2016). Симптоми и клинички знаци херније диска значајно се разликују у зависности од места херније и индивидуалне реакције на бол. Хернија лумбалног диска може изазвати бол који зрачи из доњег дела леђа, једне или обе ноге, а повремено и до стопала (који се назива ишијас). Бол се може осетити као струјни удар који је интензиван, било да се стоји, хода или седи. Активности као што су савијање, стајање горе/доле, увртање и седење могу повећати нелагодност. Лежање на леђима са савијеним коленима смањује нелагодност јер ублажава притисак на нерв. Поред болова, може доћи до слабости мишића у нози или недостатка рефлекса колена или скочног зглоба. У најтежим случајевима може доћи до пада стопала или недостатка контроле над цревима или бешиком (Fardon, et al. 2014, М. S. Greenberg 2016).

Неки од узрока попуштања дискова или херније могу бити последица повреде и неправилног подизања или се чак могу јавити спонтано. Године представљају веома битан фактор у настанку дискус херније, јер са старењем дискови постају тврђи и јаки фиброзни спољни зид диска бива ослабљен (Cummins, et al. 2006). Унутрашње језгро може да се избочи или напукне кроз сузу у зиду диска, изазивајући бол када дође у контакт са нервима. Генетика, пушење и разне професионалне и рекреативне свакодневне активности могу допринети раној дегенерацији диска (Mobbs, Newcombe and Chandran 2001, Longo, et al. 2011).

Настанак дискус херније је чешће код особа између 30 и 40 година, док су људи средњих година и старије особе знатно више изложене ризику ако се баве тешким физичким радом. Лумбална дискус хернија је један од најчешћих облика бола у доњем делу леђа који је повезан са болом у ногама и који се дешава 15 пута чешће од херније цервикалног (вратног) диска. Приближно 75% лумбалне флексије и екстензије се одиграва у лумбосакралном споју, 20% на нивоу Л4/Л5 и преосталих 5% на горњим лумбалним нивоима. То је разлог због чега су лумбалне дискус херније локализоване у 90% случајева у доња два нивоа, с тиме да су оне на нивоу Л5/С1 два пута чешће у односу на суседни горњи ниво (Kovacevic 2019). Диск хернија се јавља у 8% случајева у цервикалном (вратном) региону и само 1 до 2% случајева у горњем до средњем делу леђа (грудни део) (Jordan, Konstantinou and O'Dowd 2011).

2.2. Методе дијагностиковања и третирања хернијације диска

Постављање дијагнозе лумбалне дискус херније није увек једноставно. Лекари користе три врсте информација за постављање дијагнозе: историју болести и физикални преглед, електродијагностичке студије и најчешће, дијагнозу постављају на основу радиолошких снимака. Главно дијагностичко тестирање херније лумбалног диска су технике снимања као што су рендген, мијелографија, компјутерска томографија и магнетна резонанца.

2.2.1. Методе дијагностиковања хернијације диска

Рендгенски снимци дају добру видљивост коштаних пршљенова у кичми и могу обезбедити информацију лекару да ли је неки од њих сувише близу један другом, као и да ли постоје артротичне промене, окоштавање или преломи. Самим рендгенским снимцима није могуће извршити дијагностику дискус херније, док рендгенски снимак може да пружи додатне информације о положају пршљенова, артротичним променама или преломима (Clinic, Herniated lumbar disc 2022). Преглед на магнетној резонанци представља неинвазивну процедуру која комбинује магнетно поље и радиофреквентне таласе како би се обезбедила јасна слика меких ткива кичме. За разлику од рендгенског снимка, нерви и дискови су јасно видљиви. Снимање се може, али и не мора изводити са контрастним средством који се убризгава у крвоток (Fardon, et al. 2014, Jarvik and Deyo 2002). MRI представља златни стандард у дијагностици дискус херније. Помоћу ове методе може се открити који диск је оштећен и да ли постоји компресија нерва. Такође, може се открити прекомерни раст костију, тумори кичмене мождине или апсцеси (Clinic, Herniated lumbar disc 2022). Мијелографија је специјализована рендгенска техника у којој се боја убризгава у кичмени канал, али се данас ретко користи због свог инвазивног карактера. Овај преглед може бити праћен СТ скенирањем. Компјутерска томографија је такође неинвазивна дијагностичка техника која користи рендгенски зрак и уређај за прављење 2-димензионалних слика кичме (Vitosevic, Rasulic and Medenica 2019). Може, али и не мора да се изводи са контрастним средством која се убризгава у крвоток (Fardon, et al. 2014, Jarvik and Deyo 2002). СТ је посебно користан за потврђивање који је диск оштећен (Clinic, Herniated lumbar disc 2022). Друге технике које нису засноване на сликама (енгл. *imaging*) су електромиографија (енгл. *electromyography (EMG)*) и студије нервне проводљивости (енгл. *nerve conduction studies (HCS)*). ЕМГ тестови мере електричну функцију мишића. Мале игле се забадају у мишиће и ефекти се региструју специјалном машином. НЦС је слична техника, осим што тестира колико далеко нерви преносе електрични сигнал са једног краја нерва на други. Ови тестови могу дијагностиковати слабост мишића и оштећење нерава (Fardon, et al. 2014, Jarvik and Deyo 2002).

У физикалном налазу болесника са лумбалном дискус хернијом може се уочити анталгична сколиоза, бол који се шири ка нози, моторна слабост, испади сензибилитета као и хипорефлексија. Позитивни су коренски тестови истезања, као и интензивирање бола при палпацији у пределу ишијалгичног жљеба. Због чињенице да нервни корен у лумбалној регији излази испод истоименог педикла и да је интервертебрални простор далеко испод педикла, пролабирани диск врши компресију на нервни корен који излази из интервертебралног форамена једног нивоа испод. Стога је код унилатералне дискус херније на нивоу Л4/Л5

компромитован корен L5 са карактеристичним испадом сензибилитета на предњој латералној страни потколенице, горњој страни стопала, као и испад сензибилитета према палцу стопала. Моторна слабост захвата *m.tibialis anterior* и *m.extensor halucis* због чега болесник има слабост стајања на пети. Код унилатералне дискус херније на нивоу L5/S1 компромитован је корен S1, са карактеристичним испадом сензибилитета на задњој страни потколенице, спољашњем делу пете, и испад сензибилитета према малом прсту стопала. Моторна слабост захвата перонеалну мускулатуру и *m.triceps surae*, због чега је ослабљено стајање на прстима.

Најчешћи метод оцењивања мишићне снаге је скала за тестирање мишића (Peulić, et al. 2020). У почетку се тестира снага мишића, извођењем теста хоризонтално, дакле елиминишући ефекте гравитације (M. S. Peulić 2020). Мишиће прво треба тестирати позиционирањем пацијента за преглед на столу или кревету. Ако пацијент није у стању да ангажује мишић, чак и након што је гравитација елиминисана, испитивач ставља руку на мишиће и пита пацијента да ангажује мишиће. Ово омогућава испитивачу да осети контракцију мишића, чак и ако она није видљива. На овај начин се дефинише резултат (0 и 1). Када пацијент успешно ангажује мускулатуру испитује се снага мишића против силе гравитације. Ако пацијент успешно изведе покрет притиска, испитивач повећава снагу отпора кретања до максимума, и на тај начин оцењује степен мишићне снаге за испитани мишић или мишићну групу. Мануелни тест мишићне снаге код пацијената је лако извести и не захтева било какву специјализовану опрему, што је његова основна предност. Упркос овим предностима, ова техника има и своја ограничења. Бодовање је субјективно и засновано је на перцепцији испитивача. Такође, постоји значајна варијабилност међу пацијентима јер су неки испитаници физички јачи од других. Тест не узима у обзир мишићно-скелетне поремећаје који могу утицати на тест, као што је тендинопатија или артритис. Тест зависи од мотивације пацијента, што може представљати проблем код неких пацијената (нпр. због бола, неразумевања упутстава, психолошких разлога или неких других разлога). Оцењивање мишићне снаге се врши на основу квантификације и на основу стандардне скале која се користи за одређивање степена моторичке слабости која у овом тренутку представља „златни стандард” (Naqvi and Sherman 2020):

- 0 - одсуство контракције,
- 1 - минимална контракција која не изазива кретање,
- 2 - покрет који постоји, али се не може извести против силе гравитације,
- 3 - кретање које не може да савлада отпор испитивача,
- 4 - покрет који савладава отпор испитивача до одређеног степена и
- 5 - нормална мишићна снага.

Очито, постоји недовољно јасан распон између 3 и 5 степена, чинећи одређивање вредности на скали субјективним. Неки испитивачи проширују скалу од 5 до 9 степени додавањем симбола „+“ и „-“ када је неопходно додатно проширити скалу међувредностима. Због тога је усвојена скала прилично произвољна и недовољно прецизна (Righesso, Falavigna and Avanzi 2012).

2.2.2. Методе третирања хернијације диска

У већини случајева, бол због херније диска ослабиће у року од неколико дана и пацијент може бити потпуно излечен у року од 4 до 6 недеља. Ограничавање кретања, третман хлађењем/загревањем и узимање лека може помоћи у опоравку. Препоручени медицински лекови могу да буду нпр. лекови против болова, нестероидни антиинфламаторни лекови, лекови за релаксацију мишића и стероиди. Терапија инјекцијама стероида се изводи под рендгенском флуороскопијом која укључује убризгавање кортикостероида и локалних анестетика у епидурални простор кичме. Лек се убригава поред болног места и служи за ублажавање отока и упале нерава. Око 50% пацијената ће приметити побољшање након епидуралне инјекције, али су ефекти пролазни. Инјекције се спроводе паралелно са режимом физичког вежбања. Физикална терапија као начин за ублажавање бола се изводи како би се помогло људима да се што пре врате нормалним активностима и избегну поновне повреде. Физикални тренери дају инструкције на који начин се обављају активности везане за дизање и вежбе ходања, а првенствено за побољшање мишића доњег дела леђа, ногу и стомака. Вежбе и технике јачања леђног дела представљају суштинске аспекте опоравка и даљег здравог начина живота (Fardon, et al. 2014, Kambin 2005).

Операција херније лумбалног диска, названа дискектомија, могла би бити решење ако се симптоми не промене значајно уз конзервативне терапије. Операција се такође препоручује ако постоје симптоми повреде нерва, као што су умор, слабост мишића или недостатак осећаја у ногама. Микрохируршка дискектомија почиње резом коже дужине 1-2 инча (2.53 – 5.08 cm) у средњој линији леђа. Да би се приступило повређеном диску, кичмени мишићи се сецирају и померају у страну како би се открио пршљен. Део задњег лука пршљена се уклања да би се лакше приближило корену нерва и диска. Део оштећеног диска који додирује кичмени нерв се нежно уклања помоћу посебне опреме. Алтернатива микродискектомији у неким случајевима је минимално инвазивна ендоскопска дискектомија. Изводи се тако што хирург направи мањи рез на леђима. Мале цеви, које се називају дилататори, омогућавају проширење тунела који води до пршљена повећањем пречника. Потом се такође уклања део задњег пршљенског лука и нервни корен ослобађа притиска од стране дегенерисаног диска (Ковачевић, et al. 2017). Око 80–85% пацијената се успешно опорави применом дискектомије након чега могу да се врате свакодневном раду после 6 недеља (Fardon, et al. 2014, Kambin 2005).

3. ПРЕГЛЕД ДОСАДАШЊИХ ИСТРАЖИВАЊА

Данас се радиографске процедуре као што су магнетна резонанца и компјутеризована томографија сматрају поузданим златним стандардима у дијагностици дискус херније (Al Nezari, Schneiders and Hendrick 2013, Osti and Fraser 1992). Поједини извештаји сугеришу да СТ и MRI постижу умерену до високу специфичност (0.43 до 0.97) и осетљивост (0.6 до 1.0) у дијагностици дискус херније (Jarvik and Deyo 2002), док су неке студије упоређивале тачност модалитета снимања (искључујући снимање магнетном резонанцом) у дијагностици херније лумбалног диска у којима је констатовано да СТ дискографија има највећу тачност (87%), затим СТ мијелографија (77%), регуларна СТ (74%), мијелографија (70%), дискографија са СТ-ом (64%) и на крају дискографија без СТ снимања (58%) (Milette 2000). Међутим, у неколико студија је истраживана тачност дијагностике дискус херније користећи само MRI скенирање. Истраживачи су открили да постоји велики број снимака магнетном резонанцом који су лажно позитивни (Boden, et al. 1990, Jensen, et al. 1994) и да је вероватноћа да пацијент има лумбалну дискус хернију, ако је само позитиван MRI само 8% (Trafimow and Trafimow 2016). Ово показује да само MRI скенирање није тако поуздан извор информација као што се у почетку мислило и да не би требало да се користи као једини дијагностички модалитет. Иако неке од ових техника нису пријатне за тестирање субјекта, а неке су и инвазивне, MRI и СТ скенирање су дијагностичке мере које се примењују дуги низ година, мада је време чекања на тестирање дуго (укључујући листе чекања, процедуру припреме пре скенирања, помоћ медицинског особља током процедуре, итд.). Стога, препорука је да се MRI не користи као једини модалитет за откривање и дијагностику дискус херније. Ова дисертација се зато окреће анализи два модалитета са аспекта имплементације алгоритама вештачке интелигенције: имплементацији конволуционих неуронских мрежа у сегментацији и класификацији дискус херније и класификацији сигнала са сензора конструисане плоче за ослањање, као систем за подршку одлучивању у процесу дијагнозе. У методолошком делу ове докторске дисертације биће коришћене савремене научно-истраживачке методе, а које се могу поделити на два дела: методе обраде медицинских слика и методе обраде биомедицинских сигнала.

3.1. Досадашња истраживања у обради MRI снимака кичменог стуба

Методе обраде медицинских слика комбинују више техника машинског учења (енгл. *machine learning*) како би се препознали и издвојили различити региони од интереса. Након учитавања слика, потребно је извршити иницијално филтрирање, након чега се примењују алгоритми аутоматске сегментације (нпр. коришћењем *active appearance* модела) и ревизија добијених контура интерполационим функцијама. На основу детектованих контура врши се екстракција параметара о локацији, облику и изгледу дискуса и околног ткива, који се затим прослеђују као атрибути класификатору за доношење коначне одлуке о дијагнози. Алгоритми ће бити тренирани на јавно доступним и отвореним базама MRI снимака.

Компјутерски систем дијагностике може бити од помоћи за стварање дијагностичких резултата у кратком времену. Уз то, пожељно је повећати прецизност постављања дијагнозе као и елиминисати људске грешке изазване

умором и могућим визуелним грешкама. Генерално, на MRI сликама је веома тешко извршити сегментацију региона од интереса, јер слике имају делимичне ефекте волумена који могу замаглити разграничење између различитих врста ткива. Штавише, локализација лумбалних дискова представља изазован проблем због широког спектра варијабилности у величини, облику, броју и изгледу дискова и пршљенова. Такође, тачна сегментација дуралне вреће није једноставна, због варијација у вредностима сиве боје и изобличења облика због различитих неправилности. Тренутно доступни радови о аутоматској детекцији заснивају се на полуаутоматским методама где се иницијална контура или положај неких карактеристичних тачака ручно поставља, након чега улогу преузимају алгоритми за сегментацију. Друге методе користе мануелну сегментацију, на основу које се врши екстракција неких карактеристичних вредности које описују дискус хернију (инциденција карлице (енгл. *pelvic incidence*), нагиб карлице (енгл. *pelvic tilt*), угао леђне лордозе (енгл. *lumbar lordosis angle*), сакрални нагиб (енгл. *sacral slope*), карлични радијус (енгл. *pelvic radius*), степен спондилолистезе (енгл. *grade of spondylolisthesis*). Са аспекта примене метода за сегментацију, оне се могу поделити на оне које се ослањају на графичке моделе, пробабилистичке моделе, тзв. *watershed* алгоритми, алгоритми засновани на регистрацији атласа (енгл. *atlas registration*), графова, моделе статистичког облика (енгл. *statistical shape model*), анизотропно оријентисане (енгл. *anisotropic oriented flux*) и регресионе и класификационе моделе случајних шума (енгл. *random forest*). Горе споменуте методе заснивају се на дискретним класификацијама која враћају ограничене и понекад нетачне информације о ткиву, па је додатна корекција решења неопходна.

Поједини истраживачи су користили различите приступе за дијагностику болести лумбалне кичме на интервертебралном диску. Peng, et al. (2006) су развили квантитативну и визуелну методу користећи метод сегментације са MRI слика пацијената да би издвојили шест карактеристика. Извучене карактеристике укључују дистрибуцију хернираног диска и однос хернираног дела према дуралној врећи и њен релативни интензитет сигнала. Ghosh and Chaudhary (2014) предложили су систем заснован на максимизацији вероватноће за дијагнозу лумбалне херније који је користио интензитет, карактеристике планарног облика и карактеристике текстуре изведене из методе под називом *Gray Level Co-Occurrence Matrix*. Предложена методологија је тестирана на скупу података од 35 испитаника са тачношћу од 94.86%. Bhole, Kompalli и Chaudhary (2009) су такође развили систем за сегментацију лумбалних дискова и пршљенова са MRI снимака користећи геометријске податке из T2 аксијалног, T2 сагиталног и T1 сагиталног погледа. Рапортирани резултати су укључивали тачност од 98.8% на подскупу тестирања од 67 сагиталних приказа. Okaу и Akgul (2011) су предложили други приступ користећи пирамидални хистограм усмерених градијената (енгл. *pyramidal histogram of directed gradients (HOG)*) и методу потпорних вектора и добили су тачност од 95% тестираних на 40 слика. Koh, et al. (2011) су предложили методу без нагледаног учења користећи активне контуре за сегментацију региона од интереса на сликама кичме. Добијени резултати показују дајс коефицијент од 71% на основу тест скупа од 60 слика. Schmidt, et al. (2007) су предложили модел вероватноће који израчунава различите локације интервертебралног диска на MRI снимцима. Користећи 30 слика за тестирање, постигли су тачност од 91%.

Истраживачи као што су Peкар, et al. (2007) су успоставили метод обележавања за аутоматско скенирање MRI слика коришћењем

дводимензионалних слика хоризонталног пресека кичме. Постигли су 83.3% тачности за лумбалну регију и 97% за вратну регију. Овај предложени метод је отишао корак даље од методе који су предложили Peng, et al. (2006). Horsfield, et al. (2010) су анализирали полуаутоматски приступ за идентификацију кичмене мождине на MRI сликама коришћењем активних површинских модела за дијагнозу мултипле склерозе. Ayed, et al. (2011) су применили процедуру засновану на сегментацији графова за описивање интервертебралних дискова на MRI снимцима кичме. Michoroulou, et al. (2009) су својом методом постигли 86–88% тачности за класификацију нормалног и дегенерисаног диска на сликама. Користили су методу под називом *fuzzy C-means* да би извршили полуаутоматску сегментацију дискова засновану на карактеристикама текстуре, а затим су даље имплементирали Бајесов класификатор, да би постигли 94% тачности на тест подсету од 50 ручно сегментираних дискова. Neubert, et al. (2013) су користили карактеристике интензитета сигнала и облика за дијагнозу херније дискова и дегенерације на MRI сликама како би класификовали патологију. Unal, et al. (2015) имали су за циљ да дијагностикују абнормалности диска са аксијалног приказа MRI користећи хибридни модел, који користи ручно издвојене карактеристике од стране техничара.

Међутим, све ове методе су углавном полуаутоматске, јер захтевају интеракцију корисника и експерта за постављање почетних контура/услова, ручно издвајање карактеристика итд. Слично, Hoad and Martel (2002) су користили полуаутоматску технику за сегментацију пршљенова и кичмене мождине на MRI снимцима. Процес иницијализације укључивао је интервенцију корисника да се ручно детектује кичмена мождина на сваком нивоу кичме, или да се ручно изабере 4 тачке за свако тело пршљена. Након тога, улогу преузима алгоритам активне контуре како би се сегментирао кичмени канал. Tsai (1987) је радио на детекцији хернијације на 3Д MRI и СТ запреминама диска користећи геометријске карактеристике као што су облик, величина и локација. Иако је ова методологија занимљива, врло ретко су 3Д MRI слике доступне као део редовне дијагнозе. Још једну занимљиву методологију користили су Corso, Raja'S и Chaudhary (2008) који су применили двостепени модел вероватноће за побољшање MR снимака како би покушали да реше проблем контраста на MR сликама и постигли су тачност од 96.6%.

Неке потпуно аутоматске методе су такође истраживане, као што је рад Alomari, et al. (2014) који је извршио аутоматску детекцију херније користећи тзв. *Gradient Vector Flow (GVF)* змију за почетну контуру диска, а затим додатно обучио Бајесов класификатор на добијеним резултујућим атрибутима заснованим на облику. Иако су резултати за тачност обећавајући са 92.5%, слаба осетљивост од 86.4% није се показала као обећавајућа да би ова метода могла да се користити у пракси. Ghosh, et al. (2011) су предложили пет различитих класификатора које су повезали како би обезбедили најбоље резултате потпуно аутоматске дијагнозе лумбалне кичме, постижући 94.86% тачности и 95.90% специфичности. Други аутори Ebrahimzadeh, et al. (2018) креирали су комбинацију традиционалних и нових метода за дијагнозу херније лумбалног диска на MRI снимцима. Отсу праг је комбинован са екстракцијом обележја мерењем функције форме, након чега су за класификацију коришћени вишеслојни перцептрон (енгл. *Multi-layer perceptron (MLP)*), к-најближи суседи и метода потпорних вектора. MLP и к-најближи суседи класификатори су показали тачност од 91.90% и 92.38%, респективно. Слично,

Chevrefils, et al. (2007) спојили су два приступа, тзв. алгоритме слива (енгл. *watershed*) и морфолошке методе, како би детектовали дискове на MR снимцима. Овај аутоматски метод је предложен за контролу почетних вредности центра кластера коришћењем интуитивног фази кластера. Они тврде да су формирали додатак за интуитивно расплинато кластеризовање (енгл. *intuitive fuzzy clustering*). Предложена методологија је процењена коришћењем Јакардовог коефицијента сличности (енгл. *Jaccard coefficient*) и Дајс коефицијента (енгл. *dice coefficient*), као и одзива (енгл. *recall*) и прецизности (енгл. *precision*). Друге методе укључују сегментацију цервикалног интервертебралног диска коришћењем тзв. *Hough* трансформације и предиктивних деформабилних модела, као што су они које су предложили Marquardt, et al. (2012). Иако су многи радови показали потенцијално добре резултате, треба их узети са резервом због недостатка стандардизоване магнетне резонанце дегенерације кичме (Steffens, et al. 2016).

Због тога, бројни истраживачи су напустили традиционалне методе дијагностификовања и прешли су на технике дубоког учења. Jackson, et al. (1989) су развили технике дубоког учења за откривање и сегментацију интервертебралних дискова и пршљенова на основу 2Д слика или волуметријских података. Simonyan and Zisserman (2014), He, et al. (2016), Dou, et al. (2017) су развили неколико приступа фокусираних на дубоком учењу као што су идентификација и лоцирање интервертебралних дискова и пршљенова на 2Д сликама. Cai, et al. (2016) су извршили детекцију интервертебралних дискова користећи 3Д хијерархијски модел при чему су сегментацију извршили коришћењем карактеристика изведених из дубоких неуронских мрежа. Chen, et al. (2018) и Suzani, et al. (2015) су у својим студијама користили методе дубоког учења. Chen, et al. (2018) су се фокусирали на конволуционе неуронске мреже, док су се Suzani, et al. (2015) концентрисали на неуронске мреже са трансформацијом података у једном пролазу кроз слојеве (енгл. *feed forward neural networks*). Narun, et al. (2012) развили су конволуциони радни ток неуронске мреже за аутоматско откривање интервертебралних дискова и пршљенова користећи скуп радиолошких оцена. Друге студије, попут оних које су извели Al-Kafri, et al. (2019), предложиле су неуронске мреже дубоког учења (посебно тзв. *SegNet* архитектуру) како би помогли клиничарима да дијагностикују лумбалну спиналну стенозу, тако што ће анализирати лумбалне дискове. Naq, et al. (2015) су користили статистички модел облика за идентификацију интервертебралних дискова и пршљенова на сликама магнетне резонанце високе резолуције. Zhou, et al. (2019) су предложили нову методу детекције користећи конволуциону неуронску мрежу за детектовање кичме од L1 до С нивоа, постижући боље резултате од других. Wang, et al. (2018) успоставили су метод дубоког учења за сегментацију и обележавање дискова на аксијалним MRI сликама. Mbarki, et al. (2020) предлажу коришћење конволуционих неуронских мрежа, посебно тзв. *VGG16* за откривање дискова L1-L2, L2-L3, L3-L4, L4-L5 и L5-S1, апофизе, као и за класификацију хернираних и нормалних лумбалних дискова. Иако тврде да постижу боље резултате од оних датих у литературу, са тачношћу од 93.3%, било је неких ручних интервенција, нпр. исецање слике, као и чињеница да користе само аксијални поглед за дијагнозу херније (испуцхење, протрузија, екструзија или секвестрација).

Једна од најбољих предложених методологија за аутоматизовану сегментацију и класификацију лумбалних пршљенова је она од Lu, et al. (2018) који су користили дубоко учење за анализу спиналне стенозе. Они су анализирали

сагиталне и аксијалне MRI погледе и користили су CNN за оцењивање стенозе, постижући Дајс коефицијент од 93% и тачност класе од $80.4 \pm 1.6\%$. У другом раду Pan, et al. (2021) користили су 3555 MRI снимака за сегментирање региона од интереса (енгл. *region of interest (ROI)*), након чега су израчунате средње тачке тела пршљенова, а класификација је извршена у односу на три класе – испупчење диска, диск хернијација и нормални диск. Просечна тачност класификације била је 88.76%. Ови резултати делују обећавајуће, а основна предност рада је класификација 3 класе (мултикласификациони проблем). Ипак, коришћена је само једна мрежа и то ResNet101, без истраживања других могућих адекватних дубоких мрежа и оптимизације хиперпараметара мреже.

Због резолуције слике, присуства шума, али и разлике у величини, облику и изгледу пршљенова и дискова, локализација лумбалних дискова представља тежак задатак. Ово се нарочито испољава када је стање повезано са проблемом дијагностиковања нивоа и стране херније. Стога, примена дубоког учења треба да има приоритет у односу на традиционалне алгоритме сегментације. Једноставне карактеристике за издвајање региона од интереса не постоје, па аутоматизација процеса сегментације и класификације у медицинским сликама представља изазов у истраживањима.

3.2. Досадашња истраживања у обради биомедицинских сигнала ослањања

Додатни приступ дијагностици дискус херније предстаља анализа сензорских мерења. Поред медицинског снимања, коришћењем једног од доступних модалитета снимања, за дијагнозу лумбалне дискус херније неопходна је медицинска историја и физички преглед пацијента (Al Nezari, Schneiders and Hendrick 2013). Овакав преглед обухвата низ тестова (неуролошка процена сензорних, моторичких, дубоких тетивних рефлексних функција) који помажу у одређивању могућег извора бола и потенцијалног присуства дефицита кичменог нерва (Al Nezari, Schneiders and Hendrick 2013, Shahbandar and Press 2005). Неуролошки преглед узима у обзир дерматоме на основу којих треба локализовати нервни корен у кичми. Ови тестови укључују испитивање дорзалне и плантарне флексије стопала испитивањем способности пацијената да ходају и стоје на петима и прстима стопала. На тај начин се прегледом утврђује степен захваћености нервног корена тестирањем нервних завршетака на стопалима (Al Nezari, Schneiders and Hendrick 2013). Студије показују да је лумбосакрални спој (L5/S1) одговоран за око 75% флексије и екстензије лумбосакралне кичме, 20% се дешава на нивоу L4 - L5, а горњи лумбални нивои (L3/L4, итд.) су одговорни за преосталих 5% (Ahn, et al. 2000). Cho, et al. (2009) открили су да се око 90% дискус херније налази на нивоима L4-L5 и L5-S1.

У медицини је такође познато, на основу неуролошког прегледа, да инервација мишића и подручја коже на ножним прстима потиче од нерава који се налазе између L5 и S1 кичмених дискова, док корени нерава који инервирају пете се налазе између L4 и L5 дискова кичме (Winn 2011, Greenberg 2016). Као последица тога, ако је хернија диска локализована на нивоима L4-L5 или L5-S1, нерви би трпели притисак на том специфичном нивоу, што узрокује слабост мишића и недостатак осећаја на адекватном делу стопала. Још давне 1988. године дефинисане су мапе дерматома које описују инервацију кичмених нерава, јер су

пацијенти са нервним компресијама наводили симптоме пецкања и утрнулости у дерматомима С1 и Л5, што одговара адекватним нивоима компресије корена (Kerr, Cadoux-Hudson and Adams 1988). Једна студија у књизи која истражује студију случаја у управљању болом истиче да су негативни знаци дискус херније моторни и сензорни дефицити у одговарајућим дерматомима и миотомима (Sosner 2014). Hancock, et al. (2011) истраживали су осећај, снагу мишића и рефлексе за лумбалне дерматоме и миотоме. Користили су оцењивање мишића са скалом где се број 5 сматрао нормалном функцијом, број 4 и мањи оцењени су као различити нивои абнормалности. Са овом врстом информација, пријављено је да је регион бола локализован на једном дерматому за нерве између пршљенова Л4, Л5, С1 или комбинација суседних дерматома. Сличну студију извели су Suri, et al. (2011) који су истраживали осетљивост физичког прегледа у дијагностици притискања средњег лумбалног корена нерава Л2, Л3 или Л4 или притискања ниског корена лумбалних нерава Л5 или С1. Коришћена је иста скала оцењивања као у претходно поменутој студији.

Дакле, неуролошки преглед нивоа дискус херније подразумева независно притискање прстију и пете пацијента на обе ноге и покушај да се препозна да ли постоји слабост мишића на прстима/пети. Упркос чињеници да се наводи да је неуролошки преглед поуздана процедура у дијагностици дискус херније (С. J. McCarthy, et al. 2007, Vroomen, de Krom and Knottnerus 2000), поузданост зависи од стандардизације (Vroomen, de Krom and Knottnerus 2000), а закључци о слабости мишића су субјективни и на њих могу утицати многи фактори, укључујући искуство, тежину болести итд. На основу свега се може закључити да постоји потреба за објективном проценом моторичке функције/слабости стопала, која је неинвазивна метода и која се може користити као улаз за систем подршке одлучивању за постављање дијагнозе диск херније. Идеја је да се креира систем мерења силе стопала помоћу сензора, а мерења са сензора, заједно са системом за подршку одлучивању, могу да креирају објективни неуролошки налаз.

Претходне студије мерења притиска стопала су већ обављене 1986. године, када су Lord, Reynolds and Hughes (1986) испитали нормалне статичке и динамичке обрасце притиска и њихову повезаност са реуматоидним артритисом, дијабетесом и другим болестима, показујући њихове ефекте на ове обрасце. Међутим, мерења притиска стопала су тек недавно истраживана у областима хода и држања, а у сврху дизајна обуће, дијагностику проблема са доњим удовима, спортску биомеханику или превенцију повреда (Bonato 2003, Margolis, et al. 2003, Hung, Zhang and Tai 2004, Razak, et al. 2012). Главне предности мерења силе су првенствено неинвазивност, исплативост и трајање мерења, јер она трају највише неколико минута (Razak, et al. 2012). Постојале су и антропометријске студије које су желеле да испитају разлике у половима у вези са обрасцима стајања стопала које су пронашле значајне разлике између мушких и женских костију стопала (Smith 1997). С друге стране, Murphy, et al. (2005) упоредили су површински притисак и контактну површину на средини стопала код мушкараца и жена и њихови резултати сугеришу да нема статистички значајних разлика у четири региона стопала између мушкараца и жена. Међутим, главни недостатак ове студије је био то што су упоређивани само површински максимални притисак и контактна површина у средини стопала. Periyasamy, et al. (2011) су у својој студији известили да су се други истраживачи бавили контактном површином стопала и произведеним силама током хода, са циљем да открију везу између образаца расподеле притиска и различитих болести. Поред ове студије,

многи истраживачи су испитивали проблеме са улцерацијом стопала, јер се показало да дијабетес изазива велике плантарне притиске у одређеним деловима стопала. Дијабетес се посебно истражује у овим студијама због чињенице да велики број људи пати од њега (Wild, et al. 2004), што доводи до високих медицинских трошкова (CDC 2016). Већина студија се бавила обрасцима притиска стопала током ходања (Cavanagh, Rodgers and Liboshi 1997), док је мањи њихов број истраживао функцију стопала током стајања (Periyasamy, et al. 2011). Примена резултата у овој области првенствено укључује побољшање баланса везаног за спортске и биомедицинске примене. Примене у спорту укључују оптерећење предњег дела стопала током трчања (Periyasamy, et al. 2011) и тренинг баланса у фудбалу (Gioftsidou, et al. 2006). Везано за здравствену заштиту, дистрибуције силе су истраживане у смислу нестабилности хода код старијих особа и особа са поремећајем равнотеже, са циљем да се информације о притиску стопала користе у побољшању равнотеже (Best and Begg 2006). Поред тога, у вези са побољшањем флексије диска код пацијената, постоје и студије које се баве испитивањем стања пацијента пре и после операције (Boustani, et al. 2011). Поред претходних студија, McCarthy, et al. (2007) су пријавили умерено до значајно слагање међу испитивачима коришћењем групе пацијената са болом у доњем делу леђа са ишијасом, а довели су у питање и објективност референтне стандардне процедуре мерења мишићне слабости. Они наводе да тачна дијагноза дискус херније неуролошким прегледом зависи од дијагностичког искуства лекара, тежине стања пацијената, али и сарадње са лекаром. То значи да су неуролошке процедуре које се широко користе, показале као веома поуздане у откривању дискус херније, али не постоји стандардизовано објективно мерење за дијагнозу дискус херније. Све ово доводи до мотивације да се у оквиру ове докторске дисертације изврши анализа сигнала добијених са платформе за објективна мерења вредности силе стопала и повезивања са нервним коренима.

3.3. Досадашња истраживања у имплементацији алгоритама на ФПГА чипу

С једне стране, главна предност ФПГА система за обраду сигнала је краће време анализе у односу на софтверска решења. Интелигентни систем, који је уграђен у један чип и садржи сву потребну функционалност, даје ФПГА предност у односу на неке микроконтролере, јер комбинује брзу обраду и хардверске перформансе са могућношћу софтверских промена у опису кола (Oliveira, de Souza Braga and da Mota Almeida 2010). У раду Orsila, et al. (2007) показано је да вишепроцесорска архитектура система на чипу има потенцијал да побољша перформансе целог система и смањи трошкове. Други истраживачи попут Raucher, Mtibaa и Abid (2005) су истакли предности имплементације процесора на хардверу, као што су побољшана флексибилност имплементације и дизајн (Chowdhury and Saha 2008). Chowdhury и Saha (2008) су своје резултате објаснили у претходно поменутом раду а постигли су их у временском интервалу од 1.92 ms, што гарантује извршавање у реалном времену. Они оправдавају неопходност употребе ФПГА објашњавајући да су у земљама трећег света, попут Индије, лекари тешко доступни у руралним областима (само 2% лекара живи у руралним областима). Због тога је неопходна примена преносиве опреме, велике брзине обраде података, напајана на батеријама мале снаге, чији хардвер/софтвер може да предвиди непосредну опасност по здравље и упозори пацијенте у руралним срединама да контактирају

лекаре ради неопходне неге (Chowdhury and Saha 2010). С друге стране, одговор у реалном времену и контролисана прецизност су највећи истакнути проблеми када је у питању имплементација на хардверу. Кашњење од неколико милисекунди у испоруци резултата није нешто што се може сматрати великом разликом у медицинској дијагнози дискус херније. Могло би се рећи да софтверски приступ може дати задовољавајуће резултате, посебно у сложенијим системима, јер би такве системе било веома тешко имплементирати на хардверу, без много уштеде у убрзању.

Главна мотивација за имплементацију засновану на хардверу у медицинској дијагностици је потреба за јефтиним и неинвазивним преносивим системом. Овде би се могло рећи да су главни недостатак хардвера заснованог на ASIC (енгл. *application-specific integrated circuit*) високи трошкови развоја и ниска могућност реконфигурације коју нуди (Chowdhury, Chakrabarti and Saha 2008). Насупрот томе, ФПГА решење омогућава да се нове промене у предложеном дијагностичком алгоритму пресликају на хардвер без скувих подешавања (Chowdhury, Chakrabarti and Saha 2008). Могло би се рећи да се решења ове групе аутора фокусирају на дефинисању архитектуре процесора који би искористио паралелизам који се у потпуности користи у фази закључивања, а затим би се даље користио имплементирани дизајн у процесорима као што су ФПГА, како би се предвидело могуће критично стање пацијента у раној фази (Chowdhury and Saha 2008). У те сврхе, они углавном истражују спрегу између неуро-фази система. Њихови радови теоријски истражују фази неуронске мреже за потребе система медицинске дијагностике, а затим то примењују на проблем раног откривања предстојећег критичног стања бубрега (Chowdhury and Saha 2010). У том смислу користе се само правила која имају позитиван степен валидације. Развијени систем се тестира на подацима стварних пацијената ради поређења резултата имплементиране фази неуронске мреже и „златног стандарда“ који је представљао стварно патофизиолошко стање пацијента. Тачност предвиђеног критичног стања била је 95.2% коришћењем имплементираног ФПГА система за доношење медицинских дијагностичких одлука (Chowdhury, Chakrabarti and Saha 2008). Cintra, Pimenta и Moreno (2011) су истраживали метод који је способан да детектује кардиопатије на електрокардиограмима и имплементирали су тај систем на ФПГА. Да би смањили количину узорковања података, усвојили су логику фази кластеровања. Корелационим методом на узорцима, доказали су да је могуће поставити иницијалну дијагнозу индикације кардиопатије и њихов главни допринос је процес груписања који побољшава хардверску имплементацију без губитка у тачности (постигнута тачност за тачну дијагнозу је 91%). Други аутори су такође истраживали примену VLSI фази класификатора у биомедицинским апликацијама. На пример, Jothi, Balamurugan и Narikumar (2014) су истраживали класификацију нивоа ризика од дијабетичке епилепсије и упоредили резултате са ФПГА излазом. Иако су аутори известили да се резултати добро поклапају између ФПГА и Матлаба, они не наводе како се имплементација постиже, нити наводе било какве детаље имплементације. Са сличном сврхом као и претходно истраживање, Balamurugan, Jothi и Narikumar (2012) изградиле су једноставан и робустан СИРМ фази процесор за класификацију нивоа ризика од епилепсије код пацијената са дијабетесом и добили су сличне закључке.

Фази логика се често комбинује са неуронским мрежама како би се побољшала тачност. Nilosey (2014) користио је ФПГА систем заснован на фази

логици спрегнутој са неуронском мрежом како би се добила оптимална одлука у погледу будућег патолошко-физиолошког стања пацијента. Овом методологијом тврде да се предвиђање критичног дијабетичког стања пацијента може остварити 30 дана пре стварног постизања критичног стања. Сама метода представља експертски систем своје врсте. Други приступ моделирању фази система користе Barriga, et al. (2006) који је усвојио стил моделирања фази логике користећи две стратегије: моделирање понашања користећи VHDL и структурни VHDL заснован на специфичној архитектури фази процесора. Да би искористили предности ФПГА ресурса, они разматрају различите приступе и користе окружење Xfuzzy за развој фази система. Ово окружење је засновано на програмском језику XFL3, који је програмски језик високог нивоа апстракције, чиме се истиче предност фокусирања на структуру система и спецификације понашања, а не само на програмирање, чиме се смањује време за имплементацију система.

Такође треба рећи да се медицинска дијагностика, као сложен процес, не заснива само на литературним подацима и подацима добијеним помоћу медицинских тестова, већ и на искуству лекара. Међутим, као што је већ поменуто, на субјективне одлуке лекара утичу многи фактори, укључујући окружење и емоционално стање особе (умор итд.) (Chowdhury и Saha 2010) (Lilford, et al. 1998). Поред тога, постоји и варијабилност међу лекарима у процесу одлучивања (Chowdhury и Saha 2010). Због тога мотивација за ову докторску дисертацију је била да се изврши имплементација фази система за дијагностику дискус херније на ФПГА чипу како би се задовољила анализа у реалном времену и развила јефтина преносива платформа на лицу места.

Поред напред поменутих, нема толико студија које се баве имплементацијом система са фази или Бајесовом логиком на ФПГА чипу а које се односе на медицинску дијагностику. Имплементација других, сложенијих класификатора захтева додатне библиотеке, а ефикасна и флексибилна хардверска имплементација било ког сложенијег класификатора представља изазован проблем за развој посебно дизајнираног система (Gaikwad, et al. 2019).

4. РАЗВОЈ МЕТОДОЛОГИЈЕ ЗА ОБРАДУ БИМЕДИЦИНСКИХ СИГНАЛА У ДИЈАГНОСТИЦИ БОЛЕСТИ КИЧМЕНОГ СТУБА

У овом поглављу описане су савремене методе коришћене у обради биомедицинских сигнала, са посебним освртом на конволуционе неуронске мреже у проблемима сегментације и класификације, као и класификатори за анализу 1Д биомедицинских сигнала. Методологија која је развијена у оквиру докторске дисертације је подељена у два основна сегмента: методологију за аутоматску детекцију и класификацију дискус херније на сликама магнетне резонанце и методологију за аутоматску анализу биомедицинских сигнала ослањања. Поред тога, описан је скуп података који је коришћен за имплементацију алгоритама за вештачку интелигенцију, а на крају сваког од два поменуто сегмента дато је и објашњење метрике евалуације.

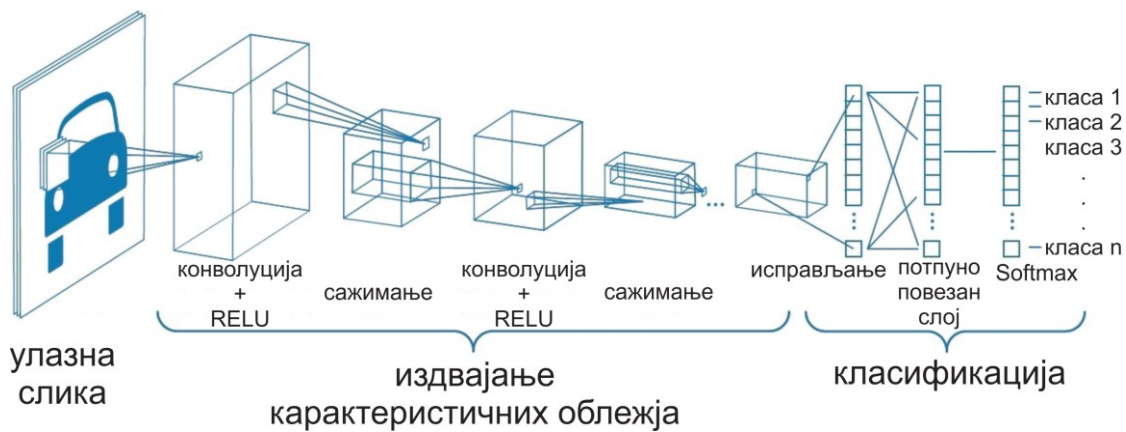
4.1. Конволуционе неуронске мреже

Слика је сачињена од матрице пиксела и представља се у 3 димензије: ширина, висина и дубина. Ширина и висина представљају димензије улазне слике, а дубина представља број канала, односно боју улазне слике (обично узима вредност 3 за слике у боји (црвена, зелена, плава) и вредност 1 за црно-беле слике).

Конволуциона неуронска мрежа полази од претпоставке да је на улазу слика монохроматска или у боји, и архитектура мреже се прилагођава тој чињеници. Конволуционе неуронске мреже су сличне регуларним неуронским мрежама у смислу да се састоје од више слојева са неуронима који имају тежинске коефицијенте које је неопходно израчунати у процесу тренинга. Класичне неуронске мреже се састоје само од потпуно повезаних слојева где је сваки неурон у слоју повезан са свим неуронима претходног слоја. Када се као улазни податак користи слика димензије 256×256 пиксела у 3 боје, сваки неурон у првом скривеном слоју би имао $256 \times 256 \times 3 = 196608$ тежинских коефицијената, што представља изузетно велики број параметара које је готово немогуће истренирати у неком разумном временском периоду, а самим тим би мрежа била склона преобучавању. Конволуционе неуронске мреже су засноване на примени конволуције, линеарном оператору који се користи у дигиталној обради сигнала. Применом конволуције слике са филтером, из слике се могу издвојити неке битне карактеристике као што су на пример ивице на слици. У том случају треба применити филтер за детектовање ивица, односно неки филтер високе фреквенције, јер су ивичне регије области са брзим променама, па је потребно из слике издвојити високофреквентне компоненте. Ово значи да се конволуциона неуронска мрежа може приказати као низ слојева при чему сваки слој врши одређене трансформације над резултатом из претходног слоја (Слика 4.1). Основне компоненте конволуционе неуронске мреже које ће детаљно бити објашњене у наставку су:

- Улазни слој је слој помоћу ког се подаци уводе у мрежу и представља улазну слику. Ако је улазна слика у боји и димензија 64×64 , овај слој има димензије $[64 \times 64 \times 3]$, док би за монохроматску слику истих димензија улазна димензија била $[64 \times 64 \times 1]$.


- Конволуциони слој узима слику из претходног слоја и конволуира је са одређеним бројем филтера, како би креирао мапу карактеристика (енгл. *feature map*). Ако се користи 12 филтера излаз има димензије [64x64x12].
- Слој активационе функције примењује активациону функцију на сваки елемент мапе. Активациона функција је углавном ReLU (енгл. *Rectified Linear Unit*), па се овај слој зове и ReLU слој. Применом активационе функције, димензије мапе се не мењају.
- Слој сажимања (енгл. *Pooling layer*) смањује број параметара тако што сажима димензије мапе по висини и ширини. На пример овај слој може смањити димензије на [16x16x12].
- Потпуно повезан слој је слој који као код регуларних неуронских мрежа садржи неуроне који су повезани са свим неуронима претходног слоја. Излаз је вектор резултата који представља скор сваке класе.



Слика 4.1 Пример конволуционе неуронске мреже


У оквиру конволуционог слоја се врши највећи број трансформација података и већина захтевних рачунања. Сваки конволуциони слој садржи унапред дефинисани број филтера, који се називају и језгра (енгл. *kernels*). Филтери имају мање просторне димензије од улазних димензија слике. Током проласка унапред, сваки од филтера се конволуира са активационом мапом, која у првом слоју представља заправо вредности пискела слике. Конволуција се врши преко целе ширине и висине слике и пошто су димензије филтера мање од димензије слике, филтер се помера за одређен број корака дуж ширине и висине слике и рачуна се скаларни производ филтера са делом слике преко ког се филтер налази (Слика 4.2). Пошто се конволуција врши само по просторним координатама, за слике у боји исти филтер се примењује на све канале, а вредности се затим сабирају. Вредности филтера представљају параметре који се обучавају. Конволуциони слојеви који се налазе близу улаза распознају неке основне карактеристике слике као што су ивице објеката на слици, док конволуциони слојеви који се налазе дубље у мрежи распознају комплексније карактеристике слике. Након конволуције слике са филтерима добија се мапа карактеристика слике чије димензије зависе од хиперпараметара који се дефинишу у конволуционом слоју, а то су број филтера, величина филтера, допуна и корак.

- Број филтера представља дубину излазне мапе карактеристика. Сваки од филтера производи као излаз посебну 2Д мапу.
- Величина филтера представља просторну димензију филтера, односно ширину и висину матрице са вредностима филтера.
- Допуна (енгл. *padding*) представља проширивање улазних димензија чиме је омогућено да се контролише просторна величина излазне мапе карактеристика. Обично се додају нуле на границе улазне мапе тако да се обезбеди да просторне димензије излазне мапе буду једнаке просторним димензијама улаза.
- Корак (енгл. *stride*) представља број пиксела за који се филтери померају при преласку преко слике. Обично је овај параметар 1 тако да се филтери померају по ширини и висини слике за 1 пиксел при конволуцији. Већа вредност овог параметра резултираће мањом димензијом излазне мапе карактеристика.



Слика 4.2 Пример конволуције

Што се тиче слоја активационе функције, овај слој се налази тик иза конволуционог слоја и на добијену мапу карактеристика која је излаз конволуционог слоја примењује се активациона функција. Активациона функција се примењује на сваки елемент мапе и на основу вредности из мапе добија се нова вредност. Применом активационе функције на овај начин димензије мапе се не мењају. Као што је већ поменуто, активациона функција која даје најбоље резултате у конволуционим неуронским мрежама је тзв. *Rectified Linear Unit (ReLU)* активациона функција. Поред ReLU активационе функције користе се и тзв. *Leaky ReLU (LReLU)*, *Exponential Linear Unit (ELU)*, *S-Shaped ReLU (SReLU)*, а Слика 4.3 приказује њихов облик.



Слика 4.3 Различите активационе функције

Слој сажимања се периодично умеће између узастопних конволуционих и активационих слојева како би се смањила просторна величина мапе добијене помоћу претходна два слоја. Овим поступком се смањује број параметара за обучавање чиме се убрзава тренирање мреже јер има мање рачунања и контролише се преобучавање. Овај слој садржи филтере који немају тежине већ само служе да смање димензије мапе. Димензије се смањују на основу величине филтера и корака који представљају два хиперпараметра у овом слоју при чему се дубина не мења. Две најзаступљеније врсте сажимања су сажимање максимумом (енгл. *max pooling*) и сажимање усредњавањем (енгл. *average pooling*). Ако се користи сажимање максимумом, сажимање се одвија узимањем локалног максимума вредности пиксела на делу слике на којој се налази филтер (Слика 4.4).



Слика 4.4 Сажимање максимумом

Ако се користи сажимање усредњавањем, сажимање се одвија узимањем средње вредности пиксела на делу слике на којој се налази филтер (Слика 4.5).



Слика 4.5 Сажимање усредњавањем

Потпуно повезани (енгл. *Fully Connected layer*) слој је идентичан слојевима који се налазе у регуларним неуронским мрежама. Садржи неуроне који су повезани са свим неуронима претходног слоја и обично се налази на крају конволуционе неуронске мреже. Сваки неурон је повезан са сваким елементом мапе из претходног слоја и у пракси се често користи неколико потпуно повезаних слојева на крају мреже. Пошто се проласком кроз конволуциону неуронску мрежу помоћу филтера смањују димензије слике односно мапе, у последњем слоју има смисла користити потпуно повезане неуроне јер је број параметара за обучавање смањен. Након потпуно повезаних слојева следи излаз мреже који представља вектор резултата са K елемената, где је K број класа улазних података. Сваки резултат представља вероватноћу припадања тој класи и за ово се обично користи *softmax* функција.

Све ово би значило да уколико се претпостави да постоји неки $N \times N$ квадратни неуронски слој који прати конволуцијски слој и ако се користи $m \times m$ филтер ω , излаз конволуционог слоја ће бити величине $(N-m+1) \times (N-m+1)$. Да би се

израчунала нелинеарна вредност улаза за неурон x_{ij}^l у посматраном слоју, морају да се сумирају доприноси из неурона претходног слоја:

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \omega_{ab} y_{(i+a)(j+b)}^{l-1} \quad 4.1$$

Претходна једначина представља процес конволуције, која се може изразити као псеудокод `conv2(x, w, 'valid')`. Тада, конволуциони слој примењује нелинеарност:

$$y_{ij}^l = \sigma(x_{ij}^l) \quad 4.2$$

Слојеви максималног сажимања су прилично једноставни и за време ових слојева нема учења. Они једноставно узимају неки $k \times k$ регион и као резултат дају једну вредност, која представља максимум у том региону. На пример, ако је њихов улазни слој $N \times N$, они ће онда дати резултујући $\frac{N}{k} \times \frac{N}{k}$ слој, пошто се сваки блок $k \times k$ смањује на само једну вредност преко *max* функције.

Претпоставимо сада да имамо неку функцију грешке E и да су познате вредности грешке након конволуционог слоја. Неопходно је израчунати грешку за претходни слој која представља парцијални извод E у односу на сваки излаз неурона $\left(\frac{\partial E}{\partial y_{ij}^l}\right)$. Компонента градијента за сваку тежину применом правила ланца, сабира доприносе свих израза у којима се променљива појављује:

$$\frac{\partial E}{\partial \omega_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} \frac{\partial x_{ij}^l}{\partial \omega_{ab}} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial E}{\partial x_{ij}^l} y_{(i+a)(j+b)}^{l-1} \quad 4.3$$

У овом случају, морају се сабрати сви x_{ij}^l изрази у којима се јавља ω_{ab} . Из пропагације познато да је $\frac{\partial x_{ij}^l}{\partial \omega_{ab}} = y_{(i+a)(j+b)}^{l-1}$. За израчунавање градијента, морају да се израчунају вредности $\frac{\partial E}{\partial x_{ij}^l}$ (које се често називају „делтама“). Делте су прилично једноставне за израчунавање, још једном користећи правило ланца:

$$\frac{\partial E}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial y_{ij}^l}{\partial x_{ij}^l} = \frac{\partial E}{\partial y_{ij}^l} \frac{\partial}{\partial x_{ij}^l} (\sigma(x_{ij}^l)) = \frac{\partial E}{\partial y_{ij}^l} \sigma'(x_{ij}^l) \quad 4.4$$

Као што се може видети, обзиром да је позната вредност грешке у тренутном слоју $\frac{\partial E}{\partial y_{ij}^l}$, могу врло једноставно да се израчунају делте $\frac{\partial E}{\partial x_{ij}^l}$ у тренутном слоју, користећи извод активационе функције $\sigma'(x)$. Пошто су познате грешке у тренутном слоју, може да се израчуна градијент у односу на тежине које користи овај конволуцијски слој. Поред израчунавања тежина за овај конволуциони слој, грешке морају да се пропагирају назад на претходни слој. Још једном се користи правило ланца:

$$\frac{\partial E}{\partial y_{ij}^{l-1}} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \frac{\partial E}{\partial x_{(i-a)(j-b)}^l} \frac{\partial x_{(i-a)(j-b)}^l}{\partial y_{ij}^{l-1}} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \frac{\partial E}{\partial x_{(i-a)(j-b)}^l} \omega_{ab} \quad 4.5$$

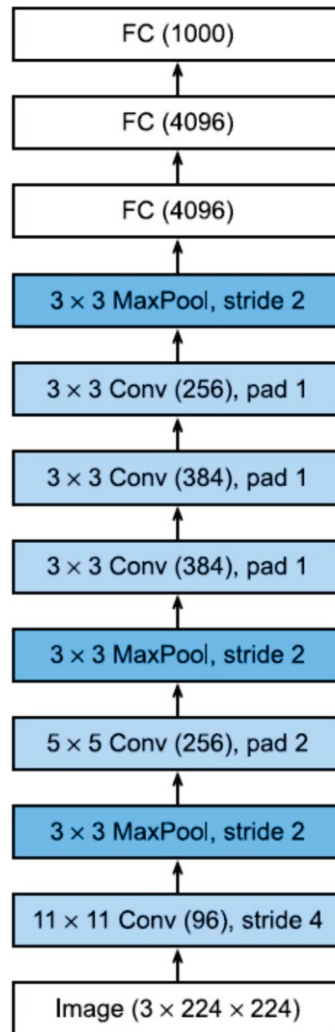
Уколико се примени једначина за пропацију унапред, може се закључити да је $\frac{\partial x_{(i-a)(j-b)}^l}{\partial y_{ij}^{l-1}} = \omega_{ab}$. Ово нам даје вредност грешке за претходни слој. Претходни израз управо подсећа на конволуцију, где се примењује филтер ω на слој; међутим, уместо израза $x_{(i+a)(j+b)}$ постоји $x_{(i-a)(j-b)}$. Поред тога, треба обратити пажњу да горњи израз има смисла само за тачке које су најмање m удаљене од горње и леве ивице. Да би се извршила корекција, неопходно је додати нуле уз горњу и леву ивицу. Након корекције, ова трансформација представља конволуцију филтером ω која је окренута дуж обе осе.

4.1.1. Архитектуре често коришћених конволуционих неуронских мрежа

Након што је 2012. конволуциона неуронска мрежа освојила награду на најпознатијем годишњем такмичењу софтверских решења за класификацију слика и детекцију објеката ILSVRC (*ImageNet Large-Scale Visual Recognition Challenge*), број истраживања у области конволуционих неуронских мрежа је порастао и значајни напредак се прави сваке године.


Из године у годину истраживачи су стварали нове архитектуре конволуционих мрежа са све бољим перформансама. Архитектуре као што су LeNet, AlexNet и VGG су сличне јер све укључују издвајање карактеристика путем серије слојева конволуције и сажимања, након чега следи накнадна обрада преко потпуно повезаних слојева (Zhang, et al. 2021). Напредак који су AlexNet и VGG направили у односу на LeNet (LeCun, et al. 1998) углавном се огледа у томе што ове накнадне мреже проширују и продубљују слојеве конволуције и сажимања.

AlexNet (Krizhevsky, Sutskever and Hinton 2012) се сматра архитектуром која је популаризовала конволуционе неуронске мреже у области рачунарске визије, након што је 2012. године мрежа победила на поменутом такмичењу ILSVRC. Мрежа је показала изузетне перформансе у односу на остале кандидате и постигла *top-5 error rate* од само 15.4% (*top-5 error rate* је проценат слика чије класе нису у листи 5 класа са највише вероватноће према излазу модела). Мрежа се састојала од 5 конволуционих слојева који су се налазили један иза другог уз понеки слој сажимања који је био убачен након неких од конволуционих слојева (Yan, Yoshua and Geoffrey 2015) (Слика 4.6). За функцију активације коришћен је ReLU, која се иначе користи након сваког конволуционог слоја. На крају су се налазила 3 потпуно повезана слоја, од којих је у прва два слоја коришћена техника избацавања (енгл. *dropout*) што је подразумевало „гашење“ одређених неурона приликом тренирања како би се контролисало преобучавање. Такође, на тренинг скупу су коришћене транслације и ротације слика како би се проширио тренинг скуп података.



Слика 4.6 Архитектура AlexNet мреже

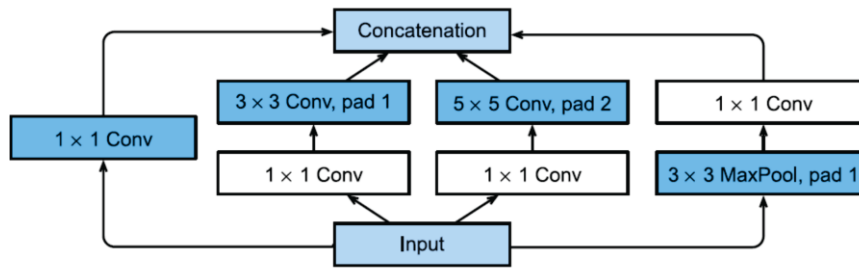
VGG Net је архитектура која се појавила 2014. године и на ILSVRC такмичењу такође је постигла значајне резултате. Архитектура је заснована на AlexNet мрежи, у смислу да има 3 потпуно повезана слоја на крају, као и да се у активационим слојевима користи ReLU функција, али је мрежа дубља (Simonyan and Zisserman 2014) (Слика 4.7). Ова мрежа користи још мањи филтер у првом конволуционом слоју у односу на претходне две мреже и његова величина је 3x3.



Слика 4.8 Архитектура GoogleNet мреже

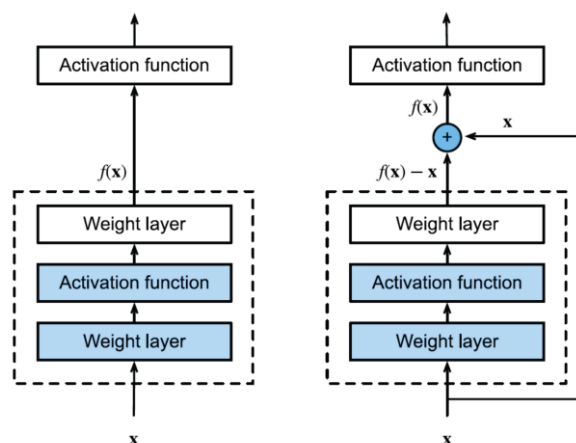
Карактеристичне особине ове архитектуре су:

- Коришћење кернела димензије 1x1 доводи до значајног смањења параметара, чиме се омогућава креирање дубље мреже, а да се не повећа захтевани простор на хард диску.
- Сажимање усредњавањем на глобалном нивоу. Слој који обавља ову функцију се налази на крају мреже, уместо потпуно повезаног слоја (као што је у претходно описаним архитектурама). Овом слоју се на улаз доводе карактеристике димензија 7x7, и он их смањује на димензије 1x1. На овај начин се слој параметара који се тренирају смањује на 0 и повећава се прецизност за 0.6%.
- Модул започињања (енгл. *Inception module*) је нешто што није постојало у претходним архитектурама и подразумева да је мрежа састављена од 9 модула који се понашају као мрежа у мрежи. У њему се налазе кернели димензија 1x1, 3x3 и 5x5, као и филтер који служи за сажимање максимумом, димензија 3x3. На ова 4 филтера се паралелно доводе подаци који долазе на улаз овог модула, а са њих се подаци одводе у један филтер који резултате обраде саставља у један ланац.
- Нема потпуно повезаних слојева и за сажимање се користи сажимање усредњавањем.




Слика 4.9 Модул започињања

Вреди напоменути да коришћење дубоких конволуционих мрежа може довести до смањења тачности класификације како се дубина повећава. He, et al. (2016) су, да би превазишли овај проблем, развили ResNet дубоку резидуалну мрежну архитектуру користећи технику резидуалног блока, која је показала значајан утицај на тачност на ImageNet скупу података. Са њим је ResNet освојио *ImageNet Large-Scale Visual Recognition Challenge 2015*. године. Оваква архитектура је имала велики утицај на то како да се креирају дубоке неуронске мреже. ResNet прати VGG-ов комплетан дизајн са 3x3 конволуционих слојева. Преостали блок има два конволуциона слоја 3x3 са истим бројем излазних канала. Сваки конволуцијски слој прати слој за нормализацију и функцију активације ReLU. Затим се прескачу ове две конволуционе операције и додаје се улаз директно пре коначне функције ReLU активације (Слика 4.10). Ова врста архитектуре захтева да излаз два конволуциона слоја мора бити истог облика као и улаз, тако да се могу сабирати. Ако желимо да променимо број канала, потребно нам је да се уведе додатни 1x1 конволуциони слој за трансформацију улаза у жељени облик за операцију сабирања.



Слика 4.10 Регуларни блок (лево) и резидуални блок (десно)

Прва два слоја ResNet-а су исти као у GoogleNet-у који је претходно описан: 7x7 конволуциони слој са 64 излазних канала и кораком од 2 прати слој сажимања максимумом са кернелом 3x3 и кораком од 2. Разлика је у слоју за нормализацију серије који се додаје након сваког конволуционог слоја у ResNet-у. GoogleNet користи четири модула састављена од Insertion блокова. Међутим, ResNet користи четири модула састављена од резидуалних блокова, од којих сваки користи неколико преосталих блокова са истим бројем излазних канала.



Слика 4.11 Архитектура ResNet-18 мреже

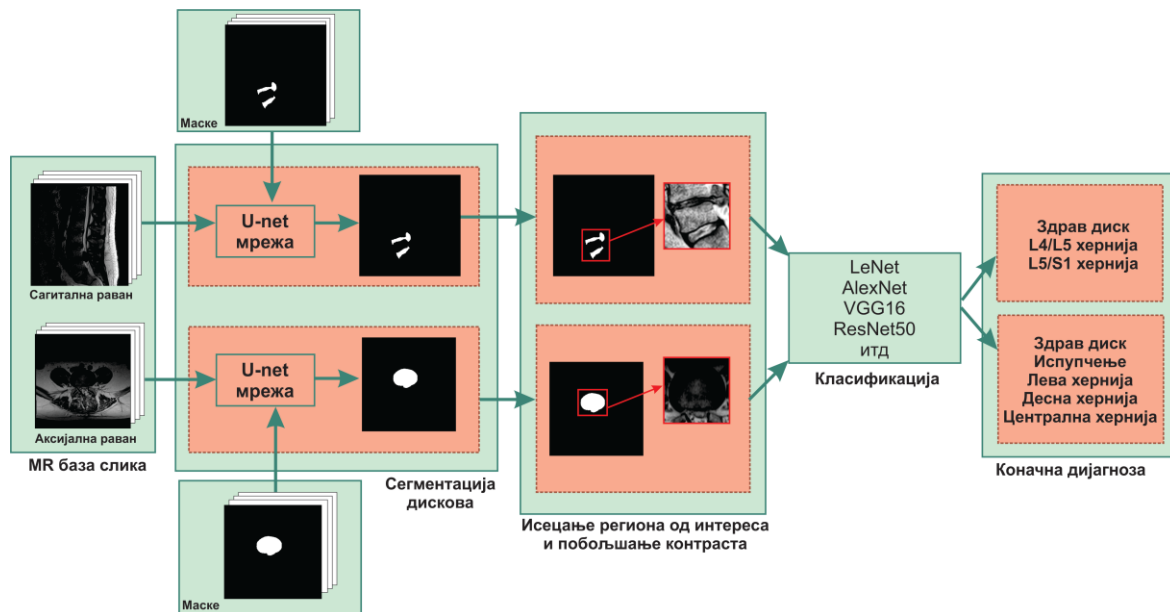
4.2. Аутоматска детекција и класификација диск херније на сликама магнетне резонанце

Методологија за аутоматску детекцију и класификацију диск херније на сликама магнетне резонанце подељена је на неколико корака, аналогно стандардној процедури претпроцесирања и класификације који се обавља у машинском учењу. Предложени систем се састоји од следећих пет делова:

- 1) Сегментација региона од интереса – у овом кораку коришћена је U-net конволуциона неуронска мрежа за издвајање области диска на аксијалном и сагиталном погледу MR слика;
- 2) Исецање региона од интереса – у овом кораку након препознавања региона, креирају се гранични оквири око сегментирани области да би се смањила област претраживања за конволуционе мреже у процесу класификације;

- 3) Побољшање контраста у пределу региона од интереса – у овом кораку примењују се различите технике обраде слике да би се побољшала исечена слика применом метода за појачавање контраста и боље истицање карактеристичних елемената региона од интереса за употребу у дијагностичком процесу;
- 4) Аугментација података (енгл. *data augmentation*) – у овом кораку врши се повећање броја података како би се повећао број слика за тренирање;
- 5) Класификација – у овом кораку слика се класификује у адекватне класе (здрав, испупчење, централна, десна или лева хернија за аксијални поглед и здрав, L4/L5, L5/S1 ниво херније на сагиталном погледу).


Слика 4.12 приказује описани концепт предложеног система.



Слика 4.12. Предложени концепт методологије успостављања дијагнозе диск херније

4.2.1. Сегментација региона од интереса (РОИ)

Већи број истраживача је показао да је архитектура неуронске мреже U-net применљива на широк спектар проблема у области сегментације медицинске слике (Moradi, Alizadehasl i Dhooge 2019, Ronneberger, Fischer i Brox 2015). Слика 4.13 приказује архитектуру U-net мреже, прилагођену за потребе ове докторске дисертације. Иако је архитектура објашњена на примеру аксијалних слика, исти принцип је примењен и на сагиталном пресеку.




Слика 4.13. Архитектура U-net мреже

Као што се види са слике, U-net има облик латиничног слова *U* и састоји се од путање контракције (енкодер) (енгл. *contraction path - encoder*) и путање проширења (декодер) (енгл. *expansion path - decoder*). Контракција се састоји од два конволуциона слоја величине 3x3 и сажимање максимумом са кернелом 2x2 (енгл. *max pooling*) на сваком нивоу. То значи да се величина улазне слике постепено смањује док се дубина постепено повећава, а дубље карактеристике се издвајају па се путања контракције изводи према идеји:


$$\text{conv_layer1} \implies \text{conv_layer2} \implies \text{max_pooling} \implies \text{dropout(опционо)}$$

Сваки процес се састоји од два конволуциона слоја и одређеног броја канала који се мењају од 3 → 16, јер процес конволуције повећава дубину слике. Црвена стрелица која показује надолу представља процедуру сажимања при чему се смањује величина слике за пола (величина ће бити смањена са 256x256 → 128x128, а допуна (енгл. *padding*) која је коришћена у овој методологији је била *padding = "same"*) (Слика 4.14).



Слика 4.14 Први корак у контракционој путањи

Овај процес се понавља још 3 пута (Слика 4.15):



Слика 4.15 Процес конволуције и сажимања максимумом поновљен 3 пута

До дна U-net мреже се долази са два конволуциона слоја, без слоја сажимања максимумом (Слика 4.16).





Figure 8.

Слика 4.16 Дно коришћене U-net мреже

Тренутна величина слике је промењена на 16x16x256. Даље, процес се наставља са путањом проширења (декодером). У декодеру се величина слике постепено повећава, а дубина постепено смањује. У сваком кораку на путу проширења, имплементирају се два узастопна 2x2 *up-conv* и два 3x3 конволуциона слоја. То значи да се путања проширења врши према формули:


$$\text{conv_2d_transpose} \implies \text{concatenate} \implies \text{conv_layer} \implies \text{conv_layer2}$$

Први део путање проширења обнавља информације са оригиналне слике, користећи описану методологију (Слика 4.17). Транспонована конволуција представља технику узорковања која проширује величину слике. Након транспоноване конволуције, ова слика се спаја са одговарајућом сликом са путање контракције и заједно стварају слику величине 32x32x256. Разлог за комбиновање информација из претходних слојева је да се добије тачније предвиђање. Након овог процеса, додају се два конволуциона слоја.



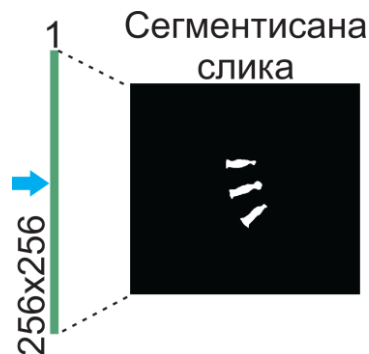
Слика 4.17 Први део путање експанзије

Једноставно, путања експанзије враћа величину мапе сегментације, али уз губитак информација о локализацији. Пошто се fine карактеристике могу изгубити у фази енкодера, постоје попречне везе које се користе за спајање мапа обележја које су једнаке величине, како би се добиле информације о локализацији од путање контракције до путање експанзије. Као и раније, овај процес се понавља три пута (Слика 4.18).



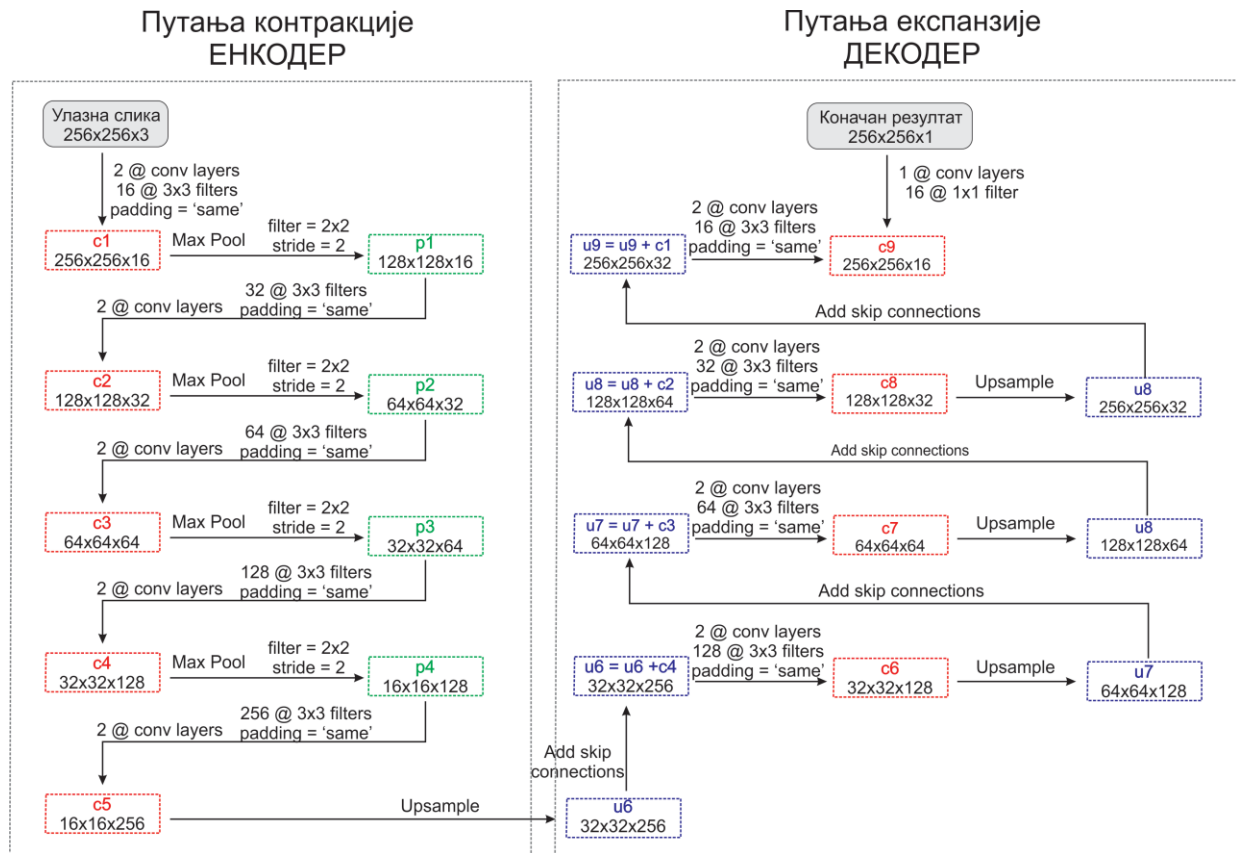
Слика 4.18 Транспонована конволуција, конкатенација и конволуција се понављају три пута

Последњи корак је адаптација слике како би испунила захтеве предвиђања. То значи да је последњи слој конволуциони слој са 1 филтером величине 1x1 (нема густог слоја у мрежи (енгл. *dense layer*)) (Слика 4.19).



Слика 4.19 Последњи корак на експанзионом путу пре креирања предвиђене маске

Слика 4.20 приказује U-net архитектуру у сумираном облику, у форми прилагођеној за имплементацију.



Слика 4.20 U-net архитектура у облику прилагођеном за имплементацију

Слика 4.20 користи следећу нотацију:

- 2@conv слојеви значе да се користе два узастопна конволуциона слоја,
- c1, c2, ..., c9 су излазни тензори конволуционих слојева,
- p1, p2, p3 и p4 су излазни тензори слоја сажимања максимумом,
- u6, u7, u8 и u9 су излазни тензори слоја у експанзионој путањи (транспонованих конволуционих).

Ово у основи значи да мрежа учи на путањи енкодера информације „ШТА“ на слици, али је изгубила информације „ГДЕ“. Након тога, декодер враћа информације „ГДЕ“ (прецизна локализација) на експанзионој путањи. Да би се добиле прецизније локације, при сваком кораку декодера користе се попречне везе спајањем излаза транспонованих конволуционих слојева са мапама карактеристика из енкодера на истом нивоу:

$$\begin{aligned}
 u6 &= u6 + c4 \\
 u7 &= u7 + c3 \\
 u8 &= u8 + c2 \\
 u9 &= u9 + c1
 \end{aligned}$$

U-Net модел пружа неколико предности у области сегментације, међу којима је и чињеница да модел омогућава истовремену употребу глобалне локализације, што значи да анализира целу слику у једном пролазу и директно креира сегментационе мапе. Такође, показало се да веома успешно ради са малим бројем узорака у тренинг скупу, посебно у поређењу са другим конволуционим мрежама (Liu, et al. 2020). Све ово осигурава да U-Net чува пун контекст улазних слика, што је велика предност у односу на приступе сегментације засноване на такозваним закрпама (енгл. *patches*) (Liu, et al. 2020). Једини очигледан недостатак архитектуре U-Net је то што учење може бити успорено у средњим слојевима дубљих модела, тако да постоји одређени ризик да мрежа научи да игнорише слојеве у којима су представљене апстрактне карактеристике. То се јавља зато што се градијенти све више разблажују, када се израчунава грешка, што на крају доводи до споријег учења тежинских коефицијената у дубљим слојевима.

До преобучавања скупа података за тренинг може доћи ако има превише епоха, док до недовољног обучавања може доћи ако их има премало. Рано заустављање (енгл. *early stopping*) представља технику која омогућава да се одреди произвољно велики број епоха за обучавање, а затим заустави обучавање када перформансе модела престану да се побољшавају.

Тренинг је првобитно био подешен на 100 епоха, а стохастички градијентни спуст је коришћен са унапред одређеном стопом учења и величинама серија (енгл. *batch size*) које су вариране да би се утврдио њихов утицај на тачност сегментације. Примењена је активациона ReLU функција. Идентичан поступак се користи за сагиталне и аксијалне погледе одвојено. Коришћено је рано заустављање са праћењем функције губитка приликом валидације и стрпљењем од 10. Оптимизација хиперпараметара је извршена у следећим опсезима:

- величина серије (енгл. *batch size*) – испитивани опсег је био од 6 до 12, са кораком од 2;
- стопе учења (енгл. *learning rate*) - испитиване вредности су биле 0.1, 0.01 и 0.001, као и њихови умношци са бројевима од 2 до 9;
- број кернела у слојевима – нпр. 8, 16, 32, 64 или 16, 32, 64, 128;
- избацавање (енгл. *dropout*) – испитивани опсег од 0.1 до 0.5 са кораком од 0.1;
- број епоха – до 100.

4.2.2. Исецање региона од интереса

Смањење области претраге врши се исецањем (енгл. *cropping*) региона од интереса и променом величине слике на величину 64x64. Треба нагласити да је класификација најпре извршена без смањења области претраге. Међутим, због ограниченог броја слика, али и разноликости попречних пресека и пуно детаља, конволуционе мреже нису биле у могућности да науче адекватне карактеристике и класификују слике са великом прецизношћу. Стога, да би се смањила област претраживања, гранични оквири су аутоматски креирани коришћењем детекције контуре око сегментираног региона од интереса (и на аксијалним и на сагиталним пресецима) и изрезани из оригиналне слике. Даља анализа је извршена на исеченим регионима и овај корак предпроцесирања показао се ефикасним у целокупном процесу класификације. Такође треба истаћи да је извршено 10% повећање величине слике у односу са гранични оквир како се не би изоставиле релевантне карактеристике региона од интереса.


4.2.3. Побољшање контраста региона од интереса и аугментација података

Како задаци машинског учења захтевају велики број слика да би се побољшале перформансе сегментације, а обзиром да у областима као што је биомедицина често нису доступне велике базе биомедицинских података (Bloice, Roth and Holzinger 2019), коришћена је процедура позната као аугментација (Bloice, Stocker and Holzinger 2017). Аугментација података (енгл. *data augmentation*) у дубоком учењу се користи у циљу повећања броја података у тренинг сету, односно повећања варијабилности могућих положаја и изгледа објеката од интереса како би мрежа имала већи број примера за учење. Метода аугментације је у овој докторској дисертацији коришћена да се вештачки повећа број слика у скупу података за трењирање (Farda, et al. 2020), док су скупови података за валидацију и тестирање остали непромењени и садржали само оригиналне и мрежи непознате слике. Неколико операција је коришћено у процесу аугментације, конкретно:

- хоризонтално пресликавање (еквивалентно пресликавању дуж x осе)
- побољшање осветљености (за овај задатак се користи простор боја HSV (енгл. *hue, saturation, value*), што значи да што су веће вредности засићености и матрице вредности, осветљеност је већа. Стога, да би се повећала осветљеност, матрице се множе вредношћу већом од 1 и обрнуто, како би се смањила осветљеност, матрице се множе са вредношћу мањом од 1). Нормализација интензитета је спроведена алгоритмом адаптивног еквализацијског хистограма са ограниченим контрастом (енгл. *Contrast limited Adaptive Histogram Equalization (CLAHE)*) са `clipLimit=2.0, tileGridSize=(4,4)`.

Коришћене су само геометријске трансформације које су омогућиле задржавање целокупних података о слици и избегавање губитка информација (Слика 4.21). Друге трансформације, које би могле довести до уклањања кључних области слике, биле су неприхватљиве због природе проблема. Такође, примена других техника, као што је нпр. вертикално окретање, такође су сматране неприкладним јер нису имале физички значај (у клиничкој пракси се не може наћи слика кичме наопако).

Целокупни скуп података је подељен на подскупове за тренинг, валидацију и тестирање у односу 80:10:10, респективно, за оба погледа.



Слика 4.21 Поступак аугментације слике (а) оригинална слика; (б) хоризонтално пресликана слика; (в) слика са побољшаном осветљеношћу

4.2.4. Издвајање карактеристичних обележја


Традиционални алгоритми подразумевају издвајање карактеристичних морфолошких обележја са региона од интереса. Стога је предмет истраживања био да се након сегментације области од интереса издвоје следеће карактеристике (Sustersic, et al. 2022):

- моменти - Момент слике је одређени пондерисани просек интензитета пиксела слике, уз помоћ којег се могу пронаћи нека специфична својства слике, као што су радијус, површина, центар итд.;
- ексцентрицитет - Ексцентрицитет елипсе која има исте секундарне моменте као и сегментисана област. Претпоставља се да ће овај пречник имати веће вредности за диск са хернијом у односу на диск без херније;
- еквивалентни пречник - Пречник круга са истом површином као и регион. Претпоставља се да ће овај пречник имати веће вредности за диск са хернијом у односу на диск без херније;
- сопствене вредности тензора инерције - За матрице коваријансе (или матрицу корелације, вишедимензионалне матрице), њихови сопствени вектори (главне компоненте) нам говоре правац и магнитуду у тачкама пресека; стога сопствене вредности дају магнитуду. Претпоставља се да ће сопствене вредности показати разлику између леве, десне и централне херније, управо због информације у правцу и магнитуди.
- однос површине граничног правоугаоника и површине диска – Количник површине која је креирана на основу правоугаоника који оивичава сегментисану површину и реалне површине диска. Претпоставља се да ће овај количник имати веће вредности за касније стадијуме дискус херније, управо због испупчености.

Опажања заснована на анализи слика диска без херније и са хернијом су имплицирала да ако се измери растојање од центра диска до ивичних тачака диска

у кругу од 360° и исцртају вредности растојања у односу на тачке, добиле би се криве јасно другачијег облика за здраве и болесне дискове (Sustersic, et al. 2022). Функције удаљености од тежишта (енгл. *Centroid Distance Function (CDF)*) је назив усвојен на основу референце (Zhang and Lu 2003) за морфолошке карактеристике слике.

Слика 4.22 приказује процедуру за израчунавање функције удаљености од тежишта. Ова функција је једна од морфолошких карактеристика (Zhang and Lu 2003) које се обично користе као алати за припрему за друге алгоритме, као што је израчунавање удаљености између граничних тачака од тежишта. Локација тежишта је фиксна у односу на форму. Да би се одредило тежиште, израчунава се просек положаја свих тачака у региону. Подаци о површини су уграђени у функцију централне удаљености, која бележи и локалне и глобалне карактеристике. Координата тежишта сваког диска мора бити одређена да би се израчунала функција растојања. Након тога користи се *Canny* метода детекције ивица за израчунавање координата ивица дискова.



Слика 4.22 Израчунавање функције удаљености од тежишта а) методологија за израчунавање функције, б) пример растојања за диск без херније, в) пример растојања за диск са хернијом

Као што је приказано на слици (Слика 4.22а), израчунава се растојање између сваке граничне тачке и тежишта диска, при чему се претпоставља да ће постојати јасна разлика између дијаграма за здрав диск (Слика 4.22б) и диск са хернијом (Слика 4.22в) (Šušteršič, Ranković and Kovačević, et al. 2021).

4.2.5. Класификација

У оквиру ове докторске дисертације, у циљу спровођења вишекласне класификације – здрав диск, испупчење, централна, десна или лева хернија за слику у аксијалној равни и здрав, Л4/Л5, Л5/С1 ниво херније за слике у сагиталној равни, коришћено је седам различитих конволуционих архитектура:

- LeNet (LeCun, et al. 1998)
- AlexNet (Krizhevsky, Sutskever and Hinton 2012)
- VGG16 (Simonyan and Zisserman 2014)
- NiN (Lin, Chen and Yan 2013)

- GoogleNet (Szegedy, et al. 2015)
- ResNet50 (He, et al. 2016)
- DiscNet (предложена архитектура у овом раду, посебно дизајнирана да одговара класификацији дискус херније, названа DiscNet)

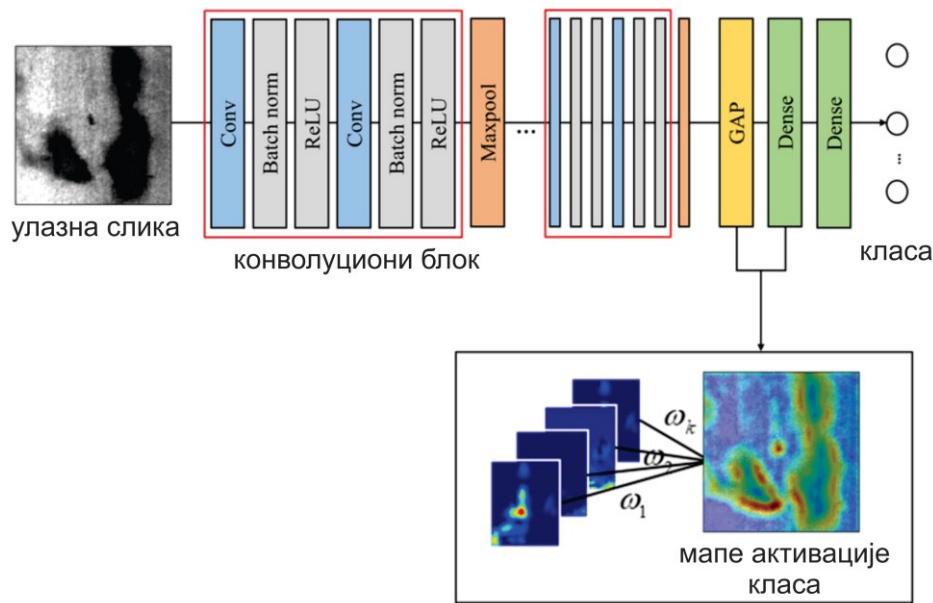
Наведене архитектуре су изабране због њихових одличних перформанси у смислу класификације са високом тачношћу у сличним задацима (Lu, et al. 2018, Mbarki, et al. 2020, Pan, et al. 2021). DiscNet је предложен као резултат великог броја различитих мрежа које су тестиране како би се пронашла најпогоднија комбинација конволуционих слојева, кернела, коефицијента учења и других хиперпараметара.

Ниједно истраживање раније није се бавило испитивањем неколико архитектура у мултикласификационом проблему са више класа за проблем дискус херније. Све претходно описане конволуционе архитектуре садрже унапред одређену архитектуру и функције активације, али други хиперпараметри као што су оптимизатор, величина серије и број епоха могу да се оптимизују. Процес претраживања се односи на опсежне претраге за најбољим одговором у простору хиперпараметара.

4.2.6. Мапе активације класа

Модел дубоког учења окарактерисани су као „црна кутија“ јер веома тешко може да се разуме како модел врши класификацију (Rudin 2019). Ово може представљати проблем када се конволуционе мреже примењују у задацима обраде медицинских слика и када модел научи да изврши класификацију на основу неодговарајућег дела слике (Merali, et al. 2021). Визуелизација модела са мапама активације класе (енгл. *class activation maps - CAM*) омогућава да се идентификују карактеристике слике које су повезане са активацијом одређених класа. Мапе активације класе пројектују тежине излазног слоја назад на последњи конволуциони слој (последњи слој са просторним информацијама) како би се одредили који региони слике, уколико се промене, највише модификују вероватноћу да слика припада одређеној класи (Merali, et al. 2021).

Како бисмо добили топлотну мапу за одређену класу, мапе карактеристика се множе са одговарајућим тежинама и на крају се сумирају. Слика 4.23 приказује процес генерисања мапе активације класа.



Слика 4.23 Процес генерисања мапе активације класа (адаптирано на основу (Zhou, et al. 2016))

Мапе активације класа су веома моћан алат за визуелизацију процеса доношења одлука у неуронској мрежи. Међутим, они имају одређена ограничења:

1. могу се применити мапе само ако конволуционе неуронске мреже садрже глобални слој сажимања усредњавањем (енгл. *Global Average Pooling (GAP)*)
2. топлотне мапе се могу генерисати само за последњи конволуциони слој.

За потребе решавања ових ограничења, предложено је мапирање активације градијента тежине класе (енгл. *Gradient Weighted Class Activation Mapping – GRAD-CAM*) (Selvaraju, et al. 2017). Овај тип мапа активације је генерализација основног типа, која се може применити на било коју врсту конволуционе неуронске мреже. Додатно, топлотне мапе се могу генерисати за сваки слој (не само за последњи). Разлика између основне и мапе активације CAM и GRAD-CAM је начин на који се израчунавају тежине за сваку од мапа карактеристика. Тачније, за GRAD-CAM се израчунавају градијенти резултата за одређену класу у односу на мапе карактеристика конволуционог слоја. Затим, ови градијенти су сажети глобалним усредњавањем да би се добиле тежине неурона. Као резултат тога, слично као CAM, израчунате тежине кодирају важност мапа карактеристика за циљну класу. Множењем мапа карактеристика са њиховим тежинама, њиховим сумирањем и применом функције ReLU на резултат добијамо мапе локализације, где су истакнути важни региони за класификацију улазне слике.

У оквиру ове докторске дисертације генерисане су мапе активације класа за насумично одабране слике који су класификоване исправно и/или погрешно. Мапе активације класа су испитане да би се видело које карактеристике слике одговарају активирању одређене класе. Ово је посебно важно да би се на лажно негативним сликама детектовале карактеристике које су одговарале активирању одређене погрешне класе.

4.2.7. Коришћени сет података

Скуп података коришћен у овој дисертацији представља комбинацију јавно доступне базе података MRI лумбалне кичме из базе података Mendelej Data (Sudirman, et al. 2019) и слика добијених од 23 пацијента из Клиничког центра Крагујевац, Србија (Clinical Centre of Kragujevac 2020). Студију сакупљања слика је одобрила Етичка комисија Клиничког центра Крагујевац, решењем број 01-11484 од 08.09.2016. године. Јавно доступни скуп података се састојао од 575 пацијената, међутим, екстраховани су само пацијенти са Л4/Л5, Л5/С1 или здравом кичмом. Табела 4.1 даје преглед броја слика по пресеку и дијагнози.

Табела 4.1. Опис коришћеног сета података са бројем слика по равни и типу херније

	Сагитални пресек					Укупно
	здрав	Л4/Л5		Л5/С1		
<i>Mendelej Data</i>	329	363		318		1010
<i>Локална база</i>	31	49		79		159
<i>Укупно</i>	360	412		397		1169
	Аксијални пресек					Укупно
	здрав	испупчење	централна	лева	десна	
<i>Mendelej Data</i>	205	56	67	85	49	500
<i>Локална база</i>	38	8	8	25	16	57
<i>Укупно</i>	243	64	75	110	65	557

Коришћени хардвер је укључивао NVIDIA Quadro RTX 6000 GPU, 64GB RAM меморије и Intel(R) Xeon(R) Gold, 6240R, CPU са 2.40GHz. Неуронске мреже су имплементирани у Python програмском језику коришћењем Tensorflow и Keras библиотека (Gulli and Pal 2017).

4.2.8. Статистичке метрике за евалуацију

У процесу сегментације, предложена аутоматизована техника је упоређена са мануелном сегментацијом коју је извршио лекар, специјалиста неурологије. Мере евалуације као што су коефицијент Дајс (енгл. *Dice*), Јакардов коефицијент сличности, тачност, прецизност и одзив (енгл. *recall*) су одређене током тренинга, валидације и тестирања у фази сегментације. Израчунате су области преклапања, између области аутоматизоване сегментације означене са S и области мануелне сегментације означене са G , користећи Дајс коефицијент сличности (Szegedy, et al. 2015):

$$D = \frac{2|S \cap G|}{|S| + |G|} \quad 4.6$$

Јакардов коефицијент, који представља пресек над унијом (енгл. *intersection over union*), израчунава се на сличан начин као Дајс и обично се користи за поређење сличности два сегментирана региона. Одређује се тако што се укупан број пиксела у пресеченом региону подели са укупним бројем пиксела у области уније.

$$JC = \frac{|S \cap G|}{|S \cup G|} \quad 4.7$$

У фази класификације, коришћене су стандардне мере евалуације као што су матрица конфузије, осетљивост и прецизност, тачност и Ф1 скор. Конфузиона матрица се може дефинисати као:

$$M = \begin{bmatrix} M_{11} & M_{12} & M_{13} & \dots & M_{1n} \\ M_{21} & M_{22} & M_{23} & \dots & M_{2n} \\ M_{31} & M_{32} & M_{33} & \dots & M_{3n} \\ M_{41} & M_{42} & M_{43} & \dots & M_{4n} \\ \dots & \dots & \dots & \dots & \dots \\ M_{n1} & M_{n1} & M_{n3} & \dots & M_{nn} \end{bmatrix} \quad 4.8$$

где n представља број класа. Важно је приметити да сви елементи на главној дијагонали представљају, у ствари, број тачних класификација у одређеној класи (енгл. *True positive*). На пример, број представљен са M_{11} одговара броју тачних класификација у класи означеној са 1. Сви остали бројеви у овом реду матрице одговарају бројевима нетачних класификација чланова класе 1 у друге класе. На пример, број представљен са M_{12} одговара броју нетачних сврставања чланова класе 1 у класу 2. Иста логика важи за случај свих осталих класа.

Осетљивост (сензитивност, одзив) (енгл. *sensitivity, recall, true positive rate (TPR)*) и специфичност (енгл. *specificity, recall, true negative rate (TNR)*) математички описују тачност теста који извештава о присуству или одсуству стања. Појединци за које је услов задовољен сматрају се „позитивним“, а они за које није, „негативним“. Осетљивост се односи на вероватноћу позитивног теста, под условом да је заиста позитиван (једн. 4.9). Специфичност се односи на вероватноћу негативног теста, под условом да је заиста негативан (једн. 4.10).

$$TPR = \frac{TP}{TP + FN} \quad 4.9$$

$$TNR = \frac{TN}{TN + FP} \quad 4.10$$

где су TP стварно позитивни узорци (енгл. *true positive*), TN стварно негативни (енгл. *true negative*), FP лажно позитивни (енгл. *false positive*), и FN лажно негативни узорци (енгл. *false negative*). Прецизност се дефинише као:

$$\text{прецизност} = \frac{TP}{TP + FP} \quad 4.11$$

Тачност је израчуната коришћењем формуле:

$$\text{тачност} = \frac{TP + TN}{TP + TN + FP + FN} \quad 4.12$$

док је F1-скор хамонијска средина прецизности и одзива:


$$F1 = 2 \cdot \frac{\text{прецизност} \times \text{одзив}}{\text{прецизност} + \text{одзив}} \quad 4.13$$

Поред тога, коришћена је *Receiver operating characteristic (ROC)* крива као и крива *precision recall (PR)*.

4.3. Алгоритми за класификацију 1Д биомедицинских сигнала

Класификациони алгоритми, или класификатори су алгоритми који мапирају скуп улазних података у одређену класу. Постоје различите врсте класификационих алгоритама, од којих свака има своје предности и мане. Различите алгоритме треба користити са различитим величинама скупова података, као и различитим типовима података.

Логистичка регресија (енгл. *Logistic regression*) је један од најпопуларнијих алгоритама у машинском учењу, за решавање проблема класификације. Излазна променљива мора бити категоричког, односно двокласног или вишекласног типа. Овај алгоритам улазном скупу додељује вредност између 0 и 1 која означава вероватноћу припадности одређеној класи на излазу. Затим се додељена вредност упоређује са одређеним степеном активације (енгл. *threshold*), да би се одредила припадност класи (Suthaharan 2016). Слика 4.24 приказује како се додељене вредности представљају на логистичкој кривој (сигмоидној функцији).



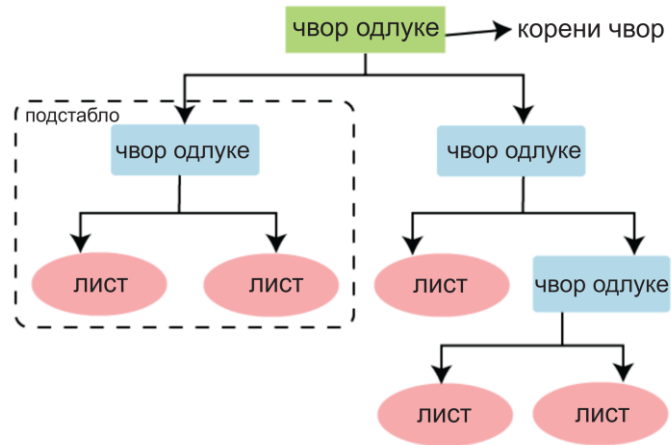
Слика 4.24 Логистичка регресија (адаптирано на основу (Suthaharan 2016))

Једна од предности коришћења овог алгоритма јесте лакше разумевање утицаја који улазни подаци имају на класу излаза. Овај алгоритам ради најбоље са бинарним излазима. Могуће је имати вишекласни излаз, али у тим случајевима прецизност није загарантована. Такође овај алгоритам може сврставати излаз у само једну класу па је, уколико је потребно класификовати податке на више начина, потребно покретати алгоритам више пута, за сваку класификацију посебно (Suthaharan 2016).

Логистичка регресија може бити биномијална, мултиномијална и ординална, при чему тип зависи од броја класа и њиховог односа. Биномијална може имати бинарни излаз, мултиномијална може имати 3 или више излазних класа које је немогуће сортирати било каквим поретком, док ординална може имати 3 или више класа које су сортиране по неком критеријуму.

Стабло одлучивања је популаран алгоритам за решавање проблема класификације, као и за проблеме рударења података (енгл. *data mining*). Алгоритам се своди на обраду познатог скупа података, и креирање стабла одлучивања (Tang, Alelyani and Liu 2014). Стабло одлучивања се састоји од чворова који чине ако-тада правила и листова у којима су записане класе излаза. Алгоритам

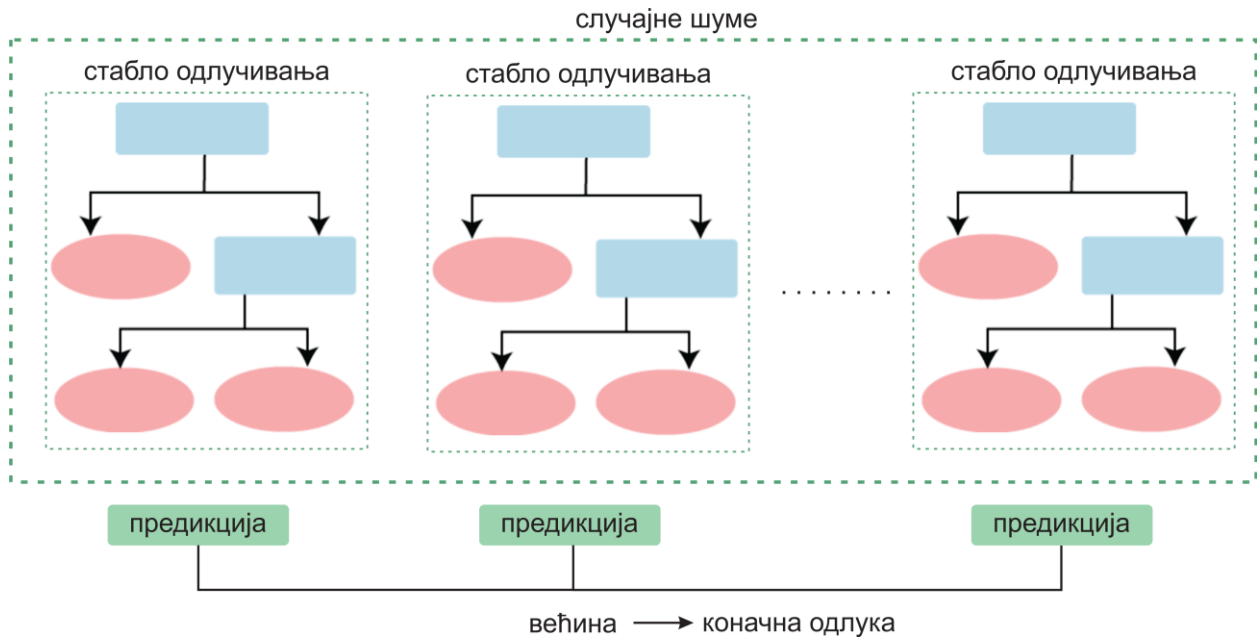
полази од корена стабла, активира правило записано у њему и одређује грану којом је потребно да се креће. Праћењем добијених грана, алгоритам пролази редом кроз чворове док не дође до листа (Слика 4.25). У тренутку када алгоритам наиђе на лист, одлука је донета и процес класификације је завршен.



Слика 4.25 Стабло одлучивања (адаптирно на основу (Tang, Alelyani and Liu 2014))

Једна од позитивних страна овог алгоритма је чињеница да није потребна велика количина података да би се стабло направило. Такође стабло није тешко визуелизовати. Међутим, у зависности од података, стабла могу постати изузетно комплексна и нестабилна. Комплексна стабла имају лошу способност генерализације (Tang, Alelyani and Liu 2014). Стабла постају нестабилна уколико су разлике између података врло мале. Нестабилна стабла могу захтевати потпуну измену структуре, додавањем минималних измена у сет података.

Случајне шуме раде на готово идентичан начин као стабло одлучивања. Једна од разлика је та да се уместо једног стабла, са познатим подацима, креира више стабала приближно исте величине (Слика 4.26). У ком ће се стаблу наћи који податак је потпуно насумично, одакле је алгоритам и добио име случајне шуме. Начин проласка кроз свако стабло је идентичан претходно описаном алгоритму. Свако стабло доноси своју засебну одлуку о томе којој класи припада излазна променљива. Затим се број понављања сваке класе пребројава, и класа која се највише пута поновила представља коначну одлуку целокупног система.



Слика 4.26 Класификатор случајне шуме (адаптирно на основу (Tang, Alelyani and Liu 2014))

Овај алгоритам је далеко напреднији од стабла одлучивања. Унапређене су способности генерализације зато што је тешко довести систем у стање преобучавања. Највећа мана овог алгоритма јесте велико време потребно за доношење одлуке, због повећаног броја правила кроз које систем мора проћи, као и повећаног броја одлука које систем мора да донесе. Још једна мана овог алгоритма јесте комплексност имплементације (Tang, Alelyani and Liu 2014).

Наивни Бајесов класификатор (енгл. *Naïve Bayes*) ради на принципу Бајесове теореме. Алгоритам претпоставља независност међу подацима и израчунава вероватноћу припадања излаза свакој од могућих класа на основу припадности улаза свакој од могућих класа унутар скупа података. На самом крају алгоритам доноси одлуку да излаз припада класи са највећом вероватноћом.

Постоји више врста наивног Бајесовог класификатора, од којих свака има своје почетне претпоставке које могу унапредити тачност добијеног излаза.

$$P(y|x_1, \dots, x_n) = \frac{P(y)P(x_1, \dots, x_n | y)}{P(x_1, \dots, x_n)} \tag{4.14}$$

Гаусов наивни Бајес полази од претпоставке да улазни подаци потпадају под Гаусову расподелу. Осим самог појављивања елемената у скупу података, у коначну одлуку улазе параметри μ и σ који представљају средњу вредност и стандардну девијацију претпостављене Гаусове криве.

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \tag{4.15}$$

Мултиномијални наивни Бајес је најпопуларнији класификатор када је у питању класификација текстуалних података. Користи се у случајевима када постоји велики број могућих излазних класа, па се као решење добија вектор вероватноћа θ .

$$\hat{\theta}_{yi} = \frac{N_{yi} + \alpha}{N_y + \alpha n} \quad 4.16$$

Категорички наивни Бајес функционише на сличан начин мултиномијалном наивном Бајесу. Користи се над небалансираним сетовима података, односно сетовима у којима су неке класе знатно доминантније у поређењу са осталима. Овај алгоритам додељује тежинске коефицијенте класама како би се постигао бољу балансираност (Tang, Alelyani and Liu 2014).

$$\hat{\theta}_{ci} = \frac{\alpha_i + \sum_{j:y \neq c} d_{ij}}{\alpha + \sum_{j:y \neq c} \sum_k d_{kj}} \quad 4.17$$

$$w_{ci} = \log \hat{\theta}_{ci} \quad 4.18$$

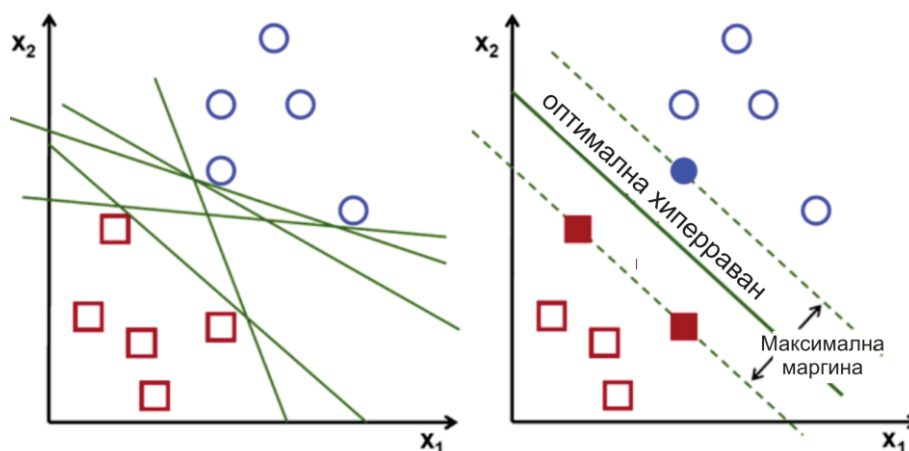
$$w_{ci} = \frac{w_{ci}}{\sum_j |w_{cj}|} \quad 4.19$$

Бернулијев наивни Бајес се користи над подацима који потпадају под мултиваријантну Бернулијеву расподелу, односно када постоји широк спектар података, али је за сваки предпостављена бинарна вредност.

$$P(x_i | y) = P(i|y)x_i + (1 - P(i|y))(1 - x_i) \quad 4.20$$

Наивни Бајесов класификатор је најбржи класификатор од свих споменутих у овој дисертацији. Међутим, једна од мана му је лоша генерализација уколико је доведен у недовољно обучено или преобучено стање. Поврх тога важно је да скуп података за тренирање буде такав да се избегну нула вероватноће.

Метода потпорних вектора је популаран алгоритам за решавање проблема класификације и регресије у машинском учењу. Алгоритам прима n-димензиони скуп података, на основу кога креира n-димензиони систем у оквиру ког су подаци представљени. Задатак алгоритма је да креира n-димензионе хиперравни помоћу којих ће поделити систем на k делова, где је k број класа. Осим раздвајања података помоћу хиперравни, задатак алгоритма је да пронађе максималне маргине међу различитим класама како би се постигла најбоља генерализација (Tang, Alelyani and Liu 2014).



Слика 4.27 Пример методе потпорних вектора на дводимензионом простору (адаптирно на основу (Tang, Alelyani and Liu 2014))

Овај алгоритам је веома ефикасан над вишедимензионим скуповима података, као и по питању искоришћења меморије. Главни недостатак овог алгоритма јесу скупови података са веома малим разликама, јер је у тим случајевима тешко постићи високу способност генерализације, због уских маргина разлике.

Метода потпорних вектора користи *hinge loss* функцију са циљем максимизације маргина разлике.


$$\min_w \lambda \|w\|^2 + \sum_{i=1}^n (1 - y_i \langle x_i, w \rangle)_+ \tag{4.21}$$

Након увођења нових података и завршене класификације, потребно је изменити тежинске коефицијенте и то на један од два начина. Уколико је класификација извршена исправно, потребно је променити градијент само уз помоћ параметара нормализације α и λ . Међутим, уколико је класификација извршена неправилно, потребно је искористити и губитак (Tang, Alelyani and Liu 2014).

$$w = w - \alpha * (2\lambda w) \tag{4.22}$$

На овај начин се обезбеђује одржавање максималне маргине разлике услед проширења скупа познатих података, са одржањем интегритета класификације.

К најближих суседа је још један алгоритам за решавање класификационих проблема. За разлику од свих осталих претходно споменутих алгоритама, KNN не креира свој модел на основу ког решава проблем, већ само чува податке и израчунава параметре када је то потребно (Tang, Alelyani and Liu 2014). Класа новог податка се налази на основу припадности класама његових K најближих суседа (Слика 4.28).



Слика 4.28 Класификатор K најближих суседа (адаптирно на основу (Tang, Alelyani and Liu 2014))

Овај класификатор је најједноставнији за имплементацију, и ради добро са свим величинама скупова познатих података. Највећа мана овог алгоритма јесте велико време чекања при одређивању K најближих суседа, јер алгоритам мора израчунати раздаљину од сваке познате тачке система до новог члана.

Како би алгоритам радио исправно, потребно је изабрати одговарајућу вредност броја K . Када број K тежи јединици, систем је нестабилан, због тога што је потребан већи број гласова како би се класа правилно изабрала. Насупрот томе, што је број K већи, односно што се већи удео скупа података узима као близак сусед, то ће и грешке у класификацији бити веће, поготово у случајевима када постоје доминантне класе у систему. Потребно је да број K буде средње величине и обично се узима као непаран број, како би се смањила могућност истог броја гласова. Не постоји ниједан сигуран начин избора броја K који ће загарантовати добре параметре класификације, али један од бољих је тестирање система са различитим односима у броју података у тренинг и тест скупу и узимање вредности која показује највећи потенцијал (Tang, Alelyani and Liu 2014).

Најчешће коришћене једначине за израчунавање растојања између тачака су: Канбера, Минковски, Чебишевљево, Еуклидово и Менхетн растојање (Tang, Alelyani and Liu 2014).

$$d(x, y) = \sum_{i=1}^m \frac{|x_i - y_i|}{|x_i + y_i|} \quad 4.23$$

$$d(x, y) = \left(\sum_{i=1}^m |x_i - y_i|^r \right)^{\frac{1}{r}} \quad 4.24$$

$$d(x, y) = \max_{1 \leq i \leq m} |x_i - y_i| \quad 4.25$$

$$d(x, y) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad 4.26$$


$$d(x, y) = \sum_{i=1}^m |x_i - y_i| \quad 4.27$$

4.4. Методологија за аутоматску анализу биомедицинских сигнала ослањања

4.4.1. Систем за мерење и поступак снимања

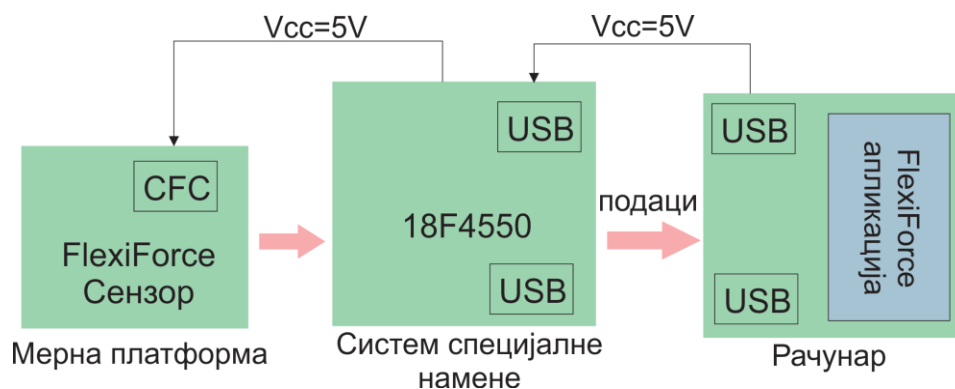
Мерни хардверски систем представља платформа за детекцију дистрибуције силе стопала која је развијена у оквиру докторске дисертације Миодрага Пеулића (M. S. Peulić 2020). Ова платформа се састоји од два идентична панела димензија 32x30 cm, и дела обележеног за стајање/мерење, величине стопала. Конструисани систем укључује четири сензора по стопалу: сензори су означени као Л1-4 за лево стопало и Д1-4 за десно стопало и стандардни су типови FlexiForce A201 сензора чији је опсег снаге од 0 до 440 N (Tekscan 2016). Сензори су постављени на мерну таблу у посебном распореду тако да представљају карактеристичне тачке људског стопала. Овај приказ карактеристичних тачака је у кореспонденцији са истраживањем у референци (Yan and Ming 2010) који су истовремено истраживали расподелу контактеног притиска и чистог напрезања у ципелама са високом

потпетицом. Користили су пет триаксијалних претварача силе у ципели, а које је комерцијализовао Anhui June Sport, Кина. У њиховом истраживању коришћен је систем са сензорима постављеним испод халукса, прве, друге и четврте метатарзалне главе, као и пете. Потврда изабраног положаја сензора добија се и у консултацији са лекарима и њиховим правилима у дијагностичком поступку. Слика 4.29 приказује поређење избора положаја сензора који су коришћени у истраживању (Yan and Ming 2010), као и у оквиру ове докторске дисертације.



Слика 4.29 Поређење положаја сензора у истраживању (Yan et al.) (Yan and Ming 2010) (лево) и у оквиру докторске дисертације (десно)

Када се активира осетљиво подручје сензора, микроконтролеру се шаље сигнал који ће конвертовати примљене податке и проследити их рачунару преко USB порта. Напајање развојне плоче се остварује везом са рачунаром преко USB-а, док се сензори на мерној табли напајају преко CFC 8 конектора (конектор за равни кабл). Обзиром на потребе дисертације за реализацију система, потребне компоненте су FlexiForce сензори (Tekscan 2016), мерна табла, развојни систем са микроконтролером и апликација на рачунару. Више детаља о мерном систему и његовим компонентама може се наћи у (Peulić, Šušteršič and Peulić 2018, Šušteršič, Ranković and Peulić, et al. 2020, M. S. Peulić 2020). Слика 4.30 приказује општу шему која описује мерни систем.

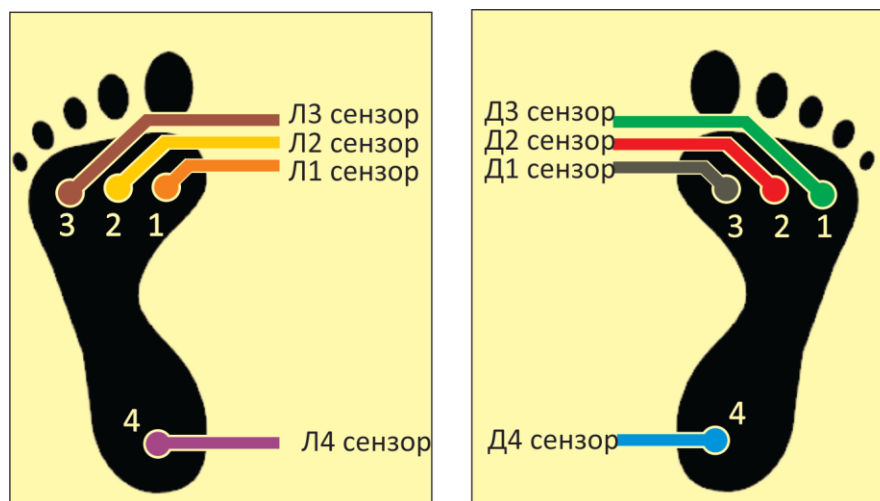


Слика 4.30 Општи преглед структуре мерног система

Сензори су направљени у два слоја. База је направљена од полиестера или полиамида за случај појаве високих температура. Проводљиви материјал (сребро)

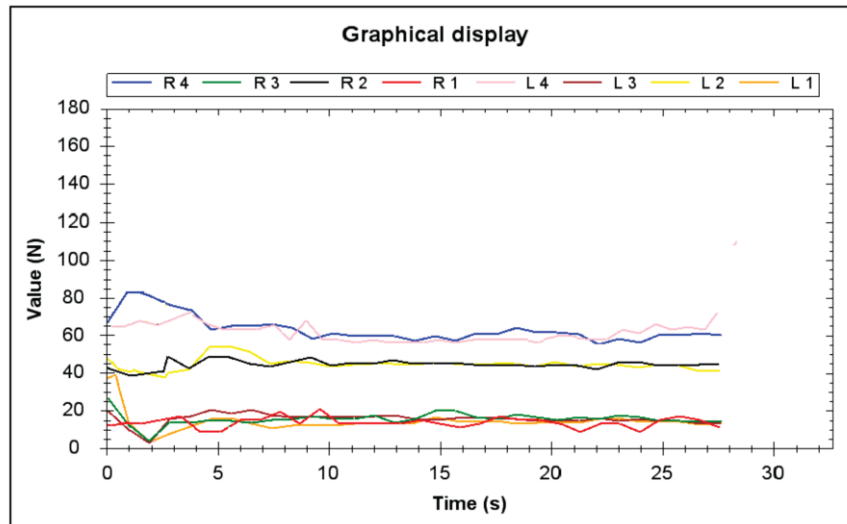
је присутан у сваком слоју, а слој мастила је осетљив на додир. Адхезивни материјал се користи за лепљење и стварање два тања слоја подлоге. Сребрни круг је активна област на врху сензора где је мастило осетљиво на додир. Цела површина области осетљиве на додир се третира као једна тачка. То значи да ће иста сила бити у средини и на ивицама сензора. Систем је тестиран са већим бројем сензора (до 8 сензора по стопи - укупно 16 сензора), како би се сензорима покрила већа површина на платформи. Резултати који су добијени су били идентични, што указује да је најмање 4 сензора по стопалу довољно за детекцију појаве дискус херније. На крају се усваја најмањи број сензора који је остварио највећу тачност. Ако би се користио други сет сензора (нпр. од другог произвођача), све док се карактеристичне перформансе сензора не мењају (пре свега осетљивост и поновљивост), систем је у стању да исправно класификује излазну дијагнозу. У зависности од произвођача сензора, ако је радни опсег другачији од коришћених Flexi Force A201 сензора, систем се мора поново калибрисати да би покрио радни опсег. Детаљније објашњење конструисане платформе, као и места где се налазе сензори Л1-Л4 и Д1-Д4 у односу на платформу може се наћи у раду (Peulić, Šušteršič and Peulić 2018, Šušteršič, Ranković and Peulić, et al. 2020).

Слика 4.31 приказује шематски изглед постављања панела и сензора на панелима. Дистрибуција четири FlexiForce сензора је симетрична код ова два панела. Излаз сензора се подешава коришћењем калибрације како би се добиле што тачније вредности (фунта (lbs), килограм (kg), њутн (N)) (M. S. Peulić 2020).



Слика 4.31 Мерни систем – шематски приказ постављања сензора на платформу

Рад платформе се покреће помоћу прекидача, када индикаторска лампица потврди да је систем спреман за употребу. Постављање мерних плоча потребно је да буде на равној површини, а размак између плоча се врши тако да одговара и/или се прилагођава испитанику. Приближно, плоче треба да буду постављене у ширини рамена испитаника. Код здравих особа, потребно је да 60% телесне тежине буде распоређено од центра стопала до пете, а 40% на предњи део стопала. Слика 4.32 приказује један такав случај код здраве особе. Овај графикон је приказан само као илустрација за субјект који стоји на обе ноге.



Слика 4.32 Дисплеј мерења здраве особе

У овој докторској дисертацији извршено је прилагођавање постављања сензора за сваког пацијента, тако да они одговарају величини стопала, како би се постигло најбоље пријањање стопала уз платформу и адекватно снимање. Ово се постиже постављањем сензора на платформу и њиховим фиксирањем на платформи за једно снимање. Ако субјект има већа/мања стопала (величина ципеле) од претходне поставке, сензори се ручно демонтирају и поново постављају како би одговарали величини стопала новог испитаника. То значи да позиционирање сензора није у потпуности фиксно у једној поставци, већ се они по потреби поново позиционирају и фиксирају, како би се поклопиле карактеристичне тачке на којима је вршено снимање - метатарзалне главе (3 сензора) и пета (1 сензор) по стопалу. Овакво репозиционирање сензора донекле представља ограничење у оквиру овог истраживања, јер се могло десити да сензори нису били адекватно позиционирани за одређене субјекте (вредности сензора су биле нула за тај сензор).

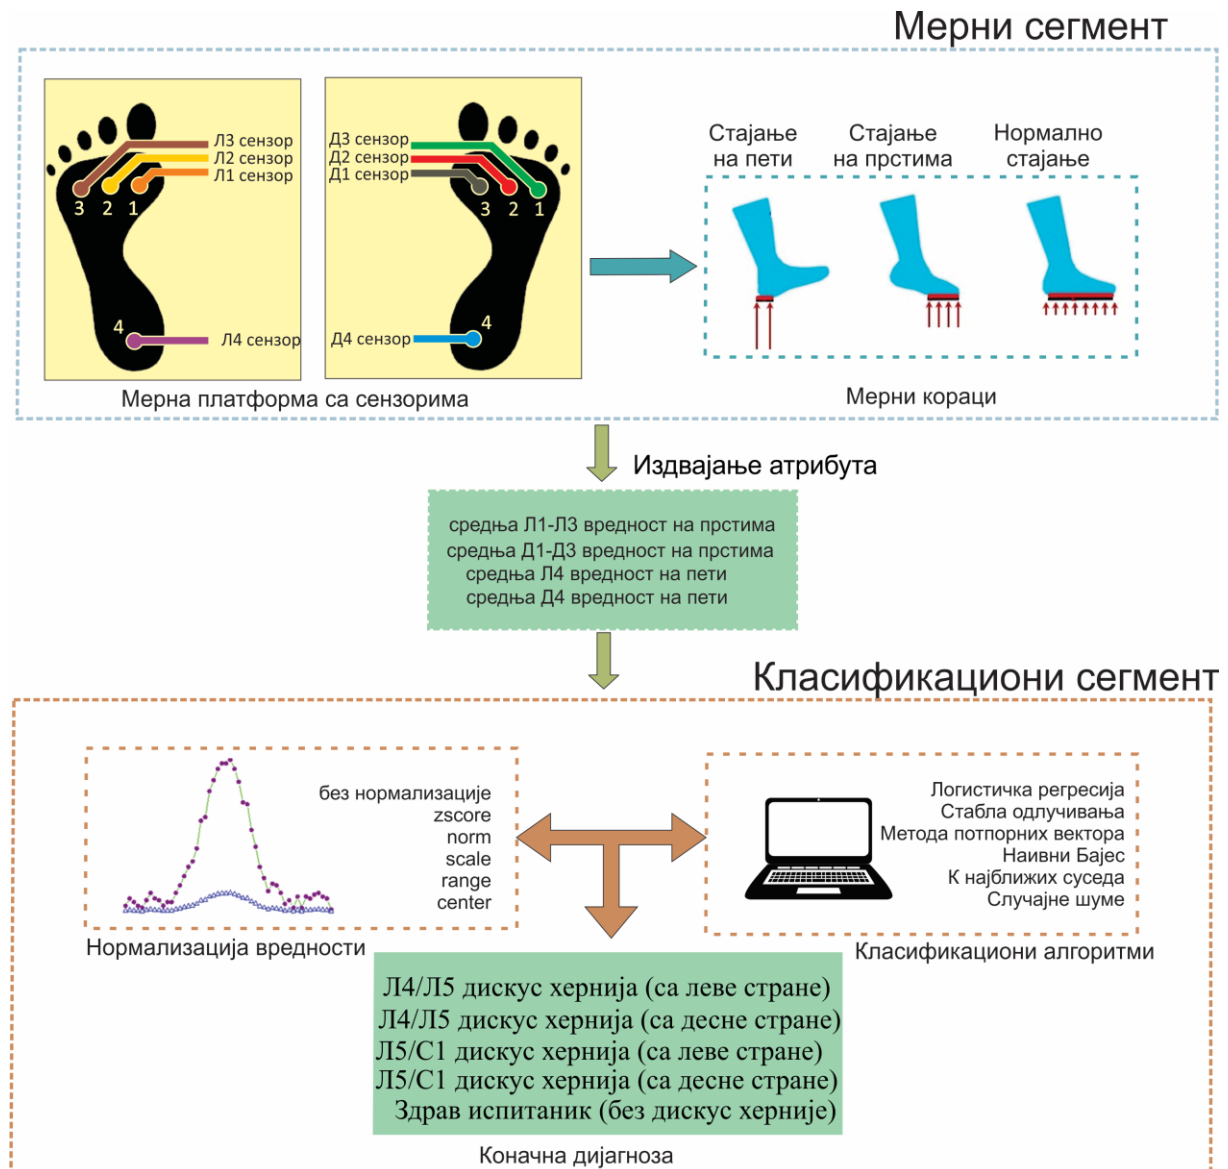
Пре поступка мерења, испитаницима се демонстрира како се користи платформа, а процедуру је испитаник испробао пре самог мерења. Мерење се састоји од три дела:

1. испитаник стоји нормално, ослоњен на обе ноге;
2. испитаник је нагнут ка прстима (израз ка прстима се користи у целој дисертацији да означи нагињање ка предњем делу стопала метатарзалне главе);
3. субјект је нагнут ка петама.

Време мерења није било ограничено, али, у сваком случају, није трајало више од пар минута. Идеја да се време мерења не ограничава била је оправдана јер код испитаника са диск хернијом може доћи до дисбаланса. Артефакти мерења могу бити присутни ако се током мерења направе изненадни покрети (нпр. неконтролисани покрети руке, савијање тела у страну, итд.). То значи да уколико тестирани субјекти губе равнотежу стајања на мерној платформи, сензори не би могли да сниме силе уколико је време мерења ограничено. Важно је било да се забележе три сегмента, без обзира на време мерења.


4.4.2. Класификација дискус херније на основу снимљених сигнала

Када су предуслови за мерење испуњени, прекидач се укључује да би се почело са снимањем. Као што је раније поменуто, када субјект стоји на платформи, три сегмента мерења се изводе један за другим у континуираном снимању - нормално стајање, стајање на прстима, и на крају стајање на петама. Прикупљени необрађени подаци се затим даље обрађују. Слика 4.33 даје шематски приказ описаног поступка мерења са примењеном методологијом.



Слика 4.33 Шематски приказ развијене методологије за дијагностику дискус херније

Као први корак, медијан филтер (енгл. *median filter*) примењен је за филтрирање сирових сигнала. Коришћен је медијан филтер 10. реда за уклањање шума на сигналу. Урађен је велики број експеримената са различитим редоследом филтера, а показало се да 10. ред даје најбоље резултате. Након тога, филтрирани сигнал је коришћен да би се издвојила три сегмента снимања – нормално стајање, период стајања на прстима и период стајања на петама. Слика 4.34 приказује пример једног непроцесираниог снимка.



Слика 4.34 Пример тросегментног снимања са јасно означеним областима нормалног стајања, стајања на прстима и стајања на пети

Теоријска основа која поткрепљује мотивацију да се изврши снимање стајања са оба стопала са пуним ослањањем, затим на прстима и потом петама, директно утиче на даљу методологију. То значи да током нормалног стајања (испрекидани плави правоугаоник), вредности $L1$ и $D1$ сензора (први сензор на левој и десној ноzi) треба да буду теоретски исте током овог периода, што би требало да буде и за $L2$ и $D2$ (јасно видљиво на сликама), $L3$ и $D3$, и $L4$ и $D4$. Током стајања на прстима (испрекидани љубичасти правоугаоник), вредности за $L4$ и $D4$ треба да буду нула, док остале вредности сензора треба да буду повећане у поређењу са нормалним стајањем (скок навише). Током стајања на пети (испрекидани зелени правоугаоник) треба да буду присутне вредности само за $L4$ и $D4$, док све остале вредности сензора треба да буду нула (скок надоле). Наравно, у пракси вредности никада нису нуле, као ни скокови у корацима нису чисти корак скокови, већ се јављају одређени шумови. Због тога, у аутоматској сегментацији извршено је филтрирање медијан филтером да би се смањио шум сирових података и да би се откриле нагле промене (скокови) у сигналима за издвајање три сегмента. Такође, дужина времена мерења не утиче на коначан резултат јер се рачуна просечна вредност за сваки сензор при нормалном стајању, стајању на прстима и стајању на пети. Како је објашњено, ова три сегмента треба да буду равне линије са два скока на местима где је позиција промењена. Коначна одлука на основу аутоматске анализе треба да одговара дијагностици лекара – ако нпр. Постоји слабост мишића на предњем делу левог стопала, дијагноза је $L5/S1$ на левој страни.

Просечне вредности силе за поменути три периода стајања се користе као улазни атрибути за даљу обраду:

1. просечна вредност силе предњег дела стопала $L1-L3$ (просек од три вредности сензора силе на левом предњем делу стопала);
2. просечна вредност силе предњег дела стопала $D1-D3$ (просек од три вредности силе сензора на десном предњем делу стопала);
3. просечна вредност силе пете $L4$ (просек вредности силе сензора на левој пети);
4. просечна вредност силе пете $D4$ (просек вредности силе сензора на десној пети).

Као почетна хипотеза усвојено је да ће слабост мишића на пети/предњем делу одговарајуће ноге (уочљива кроз смањене вредности силе у том делу стопала)

бити видљива у зависности од дијагнозе. Поред тога, уколико се вредности силе на прстима и петама обе ноге се не разликују, значи да испитаник нема хернију, што иницира да је неопходно да се прво провере разлике у силама стајања на прстима оба стопала, затим разлике у силама обе пете, и ако те разлике не превазилазе граничну вредност, испитаник је здрав (без дискус херније). Вредност прага је дефинисана на основу интерпретације бодовања на Освестри упитнику за болове у доњем делу леђа (Fairbank and Pynsent 2000) на основу које је усвојено да је 30% смањења мишићне снаге праг који означава слабост мишића. На основу свега изведена је претпоставка: ако је апсолутна вредност разлике сила стајања на прстима на левој и десној ноzi, и апсолутна вредност разлике сила стајања на петама на левој и десној ноzi, мања од 30% средње вредности максимално забележене разлике у нормалним вредностима за стајање на прстима и петама код здравих особа, тада је тестирани субјекат здрав. У супротном, тестирани субјекат има дискус хернију и потребно је урадити даљу анализу да би се дијагностиковао ниво и страна дискус херније. Треба истаћи да су максималне забележене нормалне вредности за ослањање на прстима и ослањање на петама код здравих особа биле 21.13 и 20.61 (N), са стандардном девијацијом 1.52 и 1.36 (N), респективно.

Уколико те разлике превазиђу дефинисани праг, детектована је хернија и проблем класификације је дефинисан као проблем четири класе:

1. Л4/Л5 дискус хернија на левој страни,
2. Л4/Л5 хернија диска на десној страни,
3. Л5/С1 дискус хернија на левој страни и
4. Л5/С1 дискус хернија на десној страни.

Ово значи да ако се пацијенту дијагностикује диск хернија на нивоу Л4/Л5, читава се смањена просечна вредност на сензору Л4 (у случају дискус херније на левој страни) или смањена просечна вредност на сензору Д4 (у случају диск хернија на десној страни). Насупрот томе, ако је пацијенту дијагностикована дискус хернија нивоа Л5/С1, то би значило мишићну слабост у предњем делу стопала – смањену вредност атрибута Л1-Л3 (у случају херније диска на левој страни) или Д1- Д3 (у случају дискус херније на десној страни). Међутим, може се десити да ове слабости мишића нису видљиве у зависности од тежине хернијације, као и да се пацијентима са смањеним вредностима на сензорима пете дијагностикује Л5/С1 дијагноза, па се примењују различити алгоритми класификације (Табела 4.2) у циљу стварања јединствене методе за дијагностику дискус херније.

Табела 4.2 *Оправданост имплементираних алгоритама*

Назив класификатора	Најбоље подешавање параметара	Оправданост употребе
<i>Логистичка регресија</i>	логистичка	Тестиране су и линеарна и логистичка регресија и показало се да је логистичка регресија боља
<i>Стабла одлучивања</i>	Минимални број чворова гране – 10 Одсецање (енгл. <i>pruning</i> – укључено)	На основу самог проблема и медицинске позадине, претпостављено је да логика доктора „ако-онда“ добро одговара овом алгоритму

<i>Метода потпорних вектора</i>	линеарлни кернел	Метода потпорних вектора је тестирана и са линеарним и са нелинеарним кернелом, а најбољи резултати су постигнути коришћењем линеарног кернела. Разлог за то може бити мали скуп података и мали број улазних варијабли.
<i>Наивни бајес</i>	кернел – нормалан	Због независности улазних атрибута, претпоставља се да је алгоритам погодан за проблем
<i>К-најближих суседа</i>	Број најближих суседа - 5	Модел је тестиран са низом различитих вредности за најближе суседе и 5 је изабрано као најбоље
<i>Случајне шуме</i>	Број стабала - 30	Модел је тестиран са низом различитих вредности за стабла и 30 је изабрано као најбоље

Коначно, 9 улазних карактеристика је коришћено за обуку класификатора (пол, старост, тежина, висина, просечне вредности сензора Л1-Л3, просечне вредности сензора Д1-Д3, просечне вредности сензора Л4, просечне вредности сензора Д4, тип операције (микродисектомија или дисектомија). За све очитане улазне карактеристике засноване на вредностима сензора, вредности се бележе са четири децимале. Одабрани алгоритми се комбинују са различитим методама нормализације које се даље наводе као:

- *zscore* – враћа z-скор за сваки елемент низа тако да су колоне низа центриране да имају средњу вредност од 0 и стандардну девијацију од 1,
- *norm* - враћа еуклидску норму низа (овде под нормом мислимо на 2-норму или еуклидску дужину),
- *scale* – враћа скалирани низ стандардном девијацијом,
- *range* – враћа скалирани низ у интервал облика [а б] где је а < б (интервал је дефинисан као [0 1]),
- *center* – враћа центриране податке да имају средњу вредност 0.

Исти метод је коришћен за тестирање алгоритама после операције и физикалне терапије и врши се утврђивање да ли има побољшања у јачини мишића. Након хируршке терапије код 7 испитаника је лекар дијагностиковао побољшање мишићне снаге, а након физикалне терапије код 18 од 33 испитаника лекар је дијагностиковао побољшање мишићне снаге.

4.4.3. Коришћени сет података

Скуп података је прикупљен у периоду од 2015. до 2019. године у Клиничком центру Крагујевац, Србија. Од пацијената је добијен пристанак да се прикупљени подаци користе у студији. Коначни скуп података састојао се од мерења сигнала код 33 одрасле особе са дијагнозом Л4/Л5 или Л5/С1 дискус херније и код 25 здравих испитаника. Стање дискус херније је потврђено мануелним неуролошким тестом мишића и магнетном резонанцом. Процењиване су демографске карактеристике – старост, пол, тежина, висина, које су све приказане у Табела 4.3 у облику средње вредности ± стандардне девијације.

Табела 4.3 Демографске карактеристике испитаника – здраве особе и испитаници са дијагнозом лумбалне диск херније

	Број мушкараца/жена	Старост (године)	Тежина (kg)	Висина (cm)
Л4/Л5 лево	3/6	47±13	73±13	171±4
Л4/Л5 десно	1/4	38±11	67±12	169±12
Л5/С1 лево	4/3	35±3.83	77±15.38	177±12.7
Л5/С1 десно	9/3	45±15.53	88±17.57	181±5.02
Здрави субјекти	14/11	40±12	80±18	177±10

Из табеле се може видети да је код 9 пацијената (27.3%) дијагностикована Л4/Л5 диск хернија на левој страни, код 5 пацијената (15.1%) је дијагностикована Л4/Л5 хернија диска на десној страни, 7 пацијената (21.2%) је са Л5/С1 диск хернијом на левој страни и 12 пацијената (36.4%) је са хернијом диска на десној страни на нивоу диска Л5/С1. Скуп података није укључивао анализу пацијената са нивоом диска Л3/Л4, јер не постоји медицинска позадина за везу између слабости мишића у одређеном делу стопала и ове дијагнозе. Опсежна литературна истраживања су имплицирала да се херније диска у горњем делу лумбалног дела кичме (тј. Л2, Л3) могу правилно дијагностиковати преко дерматомног радикуларног бола код само 10% пацијената. Постоји много различитих импликација у вези са хернијама горњег дела кичме и дијагностиком преко дерматома, што показује да се у великом броју случајева радикуларни бол јављао било у Л5 или С1 дерматомима. Међутим, већина ових закључака произилази из анализа на малом броју пацијената, те се стога не могу донети чврсти закључци. Такође, дискус херније горњег нивоа су ретке и у испитиваном периоду прикупљања података, због чињенице да није тако чест ниво дискус херније, у скуп података је са овом дијагнозом било могуће укључити само једног пацијента.

Критеријум за укључивање била је дискус хернија на нивоу Л4/Л5 и Л5/С1 без других обољења кичме. Пацијенти су искључени из скупа података ако је дијагностикована било која од следећих болести: синдром коња (енгл. *equina syndrome*), спинална стеноза, спондилолистеза, претходна операција кичме, неурогена клаудикација или болести које утичу на више дискова. Исто је било и са пацијентима са патологијама лумбалне кичме укључујући туморе, инфекције, фрактуре, инфламаторне спондилоартропатије, дијабетес, Пагетову болест, трудноћу или тешку остеопорозу, који су такође искључени из скупа података који је коришћен за анализу.

5. РЕЗУЛТАТИ АНАЛИЗЕ И КРЕИРАЊЕ СИСТЕМА ЗА ПОДРШКУ ОДЛУЧИВАЊУ

У овом поглављу биће описани резултати сваког корака из методологије у којој су коришћени алгоритми машинског учења. У првом делу представљени су главни резултати након имплементације алгоритама машинског учења за аутоматску сегментацију региона од интереса (материјала диска) и класификацију диск херније. Након тога, анализирани су резултати добијених биомедицинских сигнала са сензора и плоче, са фокусом на класификацији и раном откривању диск херније ван златног стандарда попут MRI. У сваком од подсекција је објашњено како овакви резултати могу да допринесу у креирању система за подршку одлучивању.

5.1. Резултати аутоматске детекције и класификације диск херније на сликама магнетне резонанце

У овом делу представљени су појединачни резултати сваког од корака – сегментације и класификације, заједно са испитивањем утицаја параметара тренинга (нпр. оптимизација хиперпараметара неуронских мрежа), како би се постигли најбољи могући резултати.

5.1.1. Резултати сегментације

Да би се утврдио утицај параметара тренинга, истражује се како број епоха, величина серије (енгл. *batch*), коефицијент учења, као и архитектура и дубина мреже утичу на тачност модела (Šušteršič, Kovačević, et al. 2022). У даљем тексту биће објашњен утицај сваког од параметара појединачно:

i) Број епоха

Тренинг и валидација су изведени независно на сликама у сагиталној и аксијалној равни. Што се тиче анализе броја епоха (енгл. *epochs (EP)*) на сликама у сагиталној равни, најпре су тестирани модели са три различите стопе учења (ЛР) (енгл. *learning rate (LR)*), ЛР=0.1, ЛР=0.01 и ЛР=0.001 на подскуповима за тренинг и валидацију. Када се упореде криве губитака за тренинг и валидациони скуп, са различитим ЛР вредностима, где је максимални број ЕП био 100, уочава се да криве губитка постају стабилне након ЕП = 30 са ЛР = 0.1 и 0.01. Међутим, за ЛР = 0.001, функција губитка на тренинг подскупу постаје стабилна тек након још неколико епоха. Може се закључити да након 35 епоха модел има тенденцију преобучавања, те је ЕП = 35 усвојен као коначан за даљу анализу.

Овај ефекат је такође видљив и када се погледа Дајс коефицијент. Коефицијент је највећи када је ЛР=0.01 и функција губитка конвергира након ЕП=35. Разумљиво је да је са ЛР=0.001 учење најспорије и постигнути Дајс коефицијент постаје стабилан након највећег броја епоха у поређењу са другим испитиваним ЛР. Слично, претрага у погледу испитивања оптималног броја епоха врши се и на аксијалним снимцима са три различите стопе учења ЛР=0.1, ЛР=0.01 и ЛР=0.001 на подскуповима за тренинг и валидацију. Ако се упореде криве губитака за тренинг-валидацију под различитим ЛР вредностима, где је максимални ЕП број 100, може се видети да криве губитка имају већу нестабилност у поређењу са

анализом на сагиталној слици и постају стабилне након ЕП = 35 са ЛР = 0.01 и 0.001. Међутим, за ЛР = 0.1, функција губитка на валидационом скупу постаје стабилна након још неколико епоха. Такође, модел за обуку на аксијалним сликама није имао проблема са преобучавањем. На основу свега изнетог, може се закључити да 35 епоха представља компромис за обе равни и на даље ће се овај број користити у анализи.

ii) Величина серије

Утицај величине серије (БС) (енгл. *batch size (BS)*) је процењен према односу заузетости GPU (енгл. *General Processing Unit*) меморије и средњим вредностима Дајс коефицијента за све слике из подскупа за валидацију са ЕП = 35. У овом истраживању, заузетост GPU меморије је била 4% - 6% и није имала веће одступање. Због тога је фокус био на анализи БС са вредностима од 6 до 12, и кораком 2. Као резултат, изабрана је вредност БС = 8 за коначан модел како би се постигле добре перформансе сегментације уз оптималну искоришћеност GPU меморије.

i) Избацивање

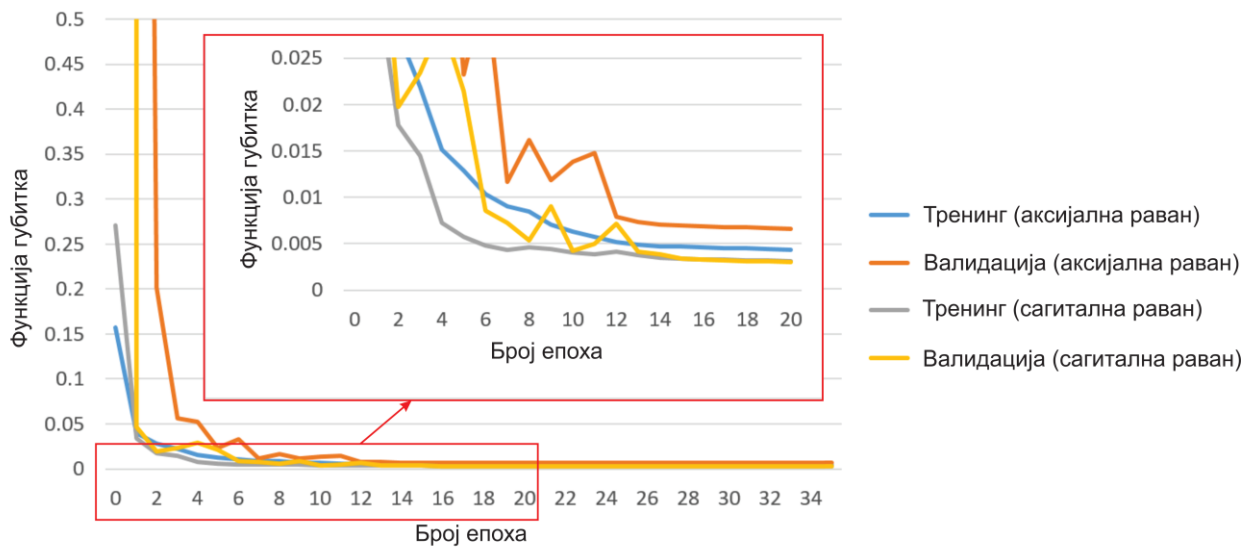
Метода избацивања (енгл. *dropout*) се заснива на насумичном уклањању одређених неурона из мреже приликом тренирања. Утицај коефицијента избацивања је процењен на основу односа заузетости GPU меморије и средњих вредности Дајс коефицијента за све слике из сета за валидацију са ЕП = 35. Није примећен већи утицај на проценат заузетости GPU меморије са променом коефицијента избацивања од 0.1 до 0.5 са кораком од 0.1. На крају, изабрана је вредност за избацивање = 0.1 за коначан модел како би се оствариле добре перформансе у процесу сегментације.

ii) Број кернела

Истражен је и утицај броја кернела у слојевима. Покушало се са неколико комбинација нпр. 8, 16, 32, 64 и 16, 32, 64, 128 бројева језгара у слојевима, а резултати су показали да је са ЕП = 35 и комбинацијом 8, 16, 32, 64, 128 бројева језгара остварен оптималан избор за постизање најбољих перформанси сегментације.


iii) Коефицијент учења

Што се тиче анализе слика у сагиталној равни, примећено је да различите ЛР вредности имају већи утицај на перформансе сегментације. Слика 5.1 приказује функцију губитака за тренинг и валидациони скуп са различитим ЛР вредностима. Као што се види са слике, све стопе учења резултују осцилацијама до око ЕП=12, након чега се постиже стабилност. Утврђено је да се са стопом учења ЛР=0.01, величином серије 8, дубином мреже до 256 карактеристика кернела (почевши са 8 кернела) остварује највећа тачност и за сагиталне и за аксијалне слике. Оптимални број епоха био је 35, након чега је модел конвергирао. Приказане су функција губитка (Слика 5.1), Дајс коефицијент (Слика 5.2) и пресек преко уније - Јакардов коефицијент сличности (Слика 5.3) током тренинга и валидације, респективно.




Слика 5.1 Функција губитка током тренинга и валидације

Резултати су показали 96.6% за Дајс коефицијент (Слика 5.2) током тренинга и 95.9% током валидације за слике аксијалног пресека, као и 90.5% током тренинга и 90.3% током валидације за слике сагиталног пресека. Резултати за Јакардов коефицијент (Слика 5.3) су 93.5% током тренинга и 92.1% током валидације за слике аксијалног, и 82.7% током тренинга и 82.4% током валидације за слике сагиталног пресека.



Слика 5.2 Коефицијент Дајс током тренинга и валидације




Слика 5.3 Јакардов коефицијент сличности током тренинга и валидације

Након проналажења оптималних параметара, вредности се процењују на непознатим сликама – тест подскуп, а Табела 5.1 приказује детаљне резултате ове анализе. У овом истраживању, заузетост GPU меморије је у сваком тренутку била од 4% - 6% и није имала веће одступање. Време тренинга за слике у аксијалној равни било је отприлике 5 минута, док је време сегментације теста било мање од 56 s (1 s по слици). Време тренинга за слике у сагиталној равни било је око 9 минута, док је време сегментације теста било мање од 120 s (1 s по слици).

Табела 5.1 Статистичке мере за тренинг, валидацију и тест подскуп у процесу сегментације коришћењем оптимизованих вредности $EP = 35$, $BS = 8$, и $LP = 0.01$


		Статистичка мера				
		тачност	Дајс	Јакард	прецизност	одзив
Аксијални поглед	Тренинг	0.997	0.966	0.935	0.992	0.960
	Валидација	0.996	0.959	0.921	0.989	0.946
	Тест	0.996	0.961	0.925	0.986	0.954
Сагитални поглед	Тренинг	0.997	0.905	0.827	0.980	0.871
	Валидација	0.997	0.903	0.824	0.977	0.871
	Тест	0.997	0.897	0.813	0.976	0.860

Слика 5.4 приказује визуелни резултат сегментације диска за пацијента са диск хернијом у аксијалној равни.



Слика 5.4 Оригинална слика (лево), ручно сегментирани диск (у средини) и аутоматски сегментирани диск (десно) за оптимизоване хиперпараметре $EP = 35$, $BC = 8$ и $LP = 0.01$ на сликама у аксијалној равни

Слика 5.5 приказује визуелни резултат сегментације за пацијента са хернијом диска у сагиталној равни.



Слика 5.5 Оригинална слика (лево), ручно сегментирани диск (у средини) и аутоматски сегментирани диск (десно) за оптимизоване хиперпараметре $EP = 35$, $BC = 8$ и $LP = 0.01$ на сликама у сагиталној равни

Коришћење неуронске мреже чини процес сегментације брзим и робусним. Такође треба напоменути да су у скупу података за сегментацију и здрави и хернирани дискови били присутни на сликама, што значи да је систем у стању да сегментира и херниране и здраве дискове са високом тачношћу. Може да се закључи да се коришћењем машинског учења, остварује брза, тачна и аутоматска сегментација на сликама (и за сагиталну и за аксијалну раван) (Šušteršič, Kovačević, et al. 2022). Овај приступ представља почетну фазу аутоматизоване дијагностике и анализе дискус херније.

Други корак је био исецање сегментисане области на величину 64×64 . То значи да су све слике исечене и да им је усвојена иста величина. Треба нагласити да је 10% повећања величине граничног оквира извршено како би се осигурало да могуће грешке у сегментацији не утичу на даљу класификацију. Поред тога, побољшање региона од интереса коришћењем CLaNE хистограмске еквализације омогућило је побољшани контраст подручја диска и одвајање од околног ткива.

Упоредивањем добијених резултата са резултатима из литературе, показало се да предложена методологија превазилази резултате који су добили други аутори (Табела 5.2). Узимајући у обзир да се у већини литературе користи само један пресек (било у аксијалној или сагиталној равни), као и да је број слика у скупу података мањи од већине скупова података у литератури, предложени приступ показује знатно боље резултате.

Табела 5.2 Поређење постигнутих резултата са резултатима из литературе

Испитивани проблем	(Al-Kafri, et al. 2019)	(Mbarki, et al. 2020)	(Lu, et al. 2018)	(Ghosh and Chaudhary 2014)	Предложена методологија			
	спинална стеноза	лумбална диск хернија	спинална стеноза	абнормалности диска (хернија, испупчење, дегенерисани дискови, итд.)	лумбална диск хернија			
Раван	аксијална	аксијална	аксијална + сагитална	сагитална	аксијална		сагитална	
Број слика	48 345	382	22 796	251	557		1169	
Метрика перформансе	Јакард	Јакард	Дајс	Дајс	Дајс	Јакард	Дајс	Јакард
Тачност	0.92	0.93	0.93	0.82	0.961	0.925	0.897	0.813

5.1.2. Резултати издвајања карактеристика


Традиционални алгоритми подразумевају издвајање карактеристичних обележја на слици која се често могу уочити голим оком (нпр. ивице, облик), након чега бројне вредности попут обима/површине могу дати увид у разлике између поменутих обележја код здравих и болесних (хернираних) дискова пацијената. Табела 5.3 даје резултате екстракције карактеристичних обележја (Sustersic, et al. 2022).

Табела 5.3 Разлике у обележјима за аксијалне слике (средња вредност \pm стандардна девијација)

	Карактеристично обележје					
	момент (сх)	момент (су)	ексцентричност	еквивалентни дијаметар	сопствене вредности тензора инерције	однос између површине граничног правоугаоника и површине диска
Здрав диск	128.39 \pm 6.53	124.13 \pm 6.20	0.68 \pm 0.05	51.08 \pm 4.16	174.55 \pm 61.78	1.30 \pm 0.03
Испупчење	128.92 \pm 6.09	121.70 \pm 8.55	0.69 \pm 0.04	59.32 \pm 8.14	238.39 \pm 108.30	1.30 \pm 0.03
Централна хернија	125.14 \pm 9.25	120.72 \pm 17.84	0.66 \pm 0.05	57.80 \pm 7.43	223.38 \pm 93.21	1.44 \pm 0.36
Хернија са леве стране	129.24 \pm 5.33	119.15 \pm 11.32	0.63 \pm 0.10	60.66 \pm 9.92	248.43 \pm 115.38	1.44 \pm 0.30
Хернија са десне стране	124.75 \pm 8.02	115.18 \pm 13.92	0.61 \pm 0.10	60.23 \pm 8.81	242.07 \pm 101.47	1.42 \pm 0.07

Може се видети да моменти не описују адекватно разлику између нехернираних и хернираних дискова, док ексцентрицитет и еквивалентни дијаметар показују донекле разлику. С друге стране, сопствене вредности тензора инерције су се показале веома описним у разликовању ове две класе. Такође

испитана је и функција удаљености од тежишта диска, а Слика 5.6а приказује ово растојање за здрав диск без херније, док Слика 5.6б приказује растојање за диск са хернијом. Јасно је да је код нехернираних дискова број пикова два, што одговара двома најудаљенијим тачкама од тежишта на хоризонталној осци, док за хернирани диск постоји додатни пик који одговара подручју херније (Šušteršič, Ranković and Kovačević, et al. 2021).



Слика 5.6 Резултати функције удаљености од тежишта диска за
а) здрав диск, б) диск хернију

Упркос чињеници да су ови налази пружили значајан индикатор за откривање херније, показало се да је приступ мање користан у случајевима са благим испупчењем диска. Стога се методе машинског учења показују супериорнијим у процесу класификације у односу на традиционалне методе издвајања карактеристичних обележја.

5.1.3. Резултати класификације


Након успешне сегментације региона од интереса и исецања релевантног граничног оквира, укључујући повећање региона од интереса, извршена је класификација хернијације диска (здрав диск, испупчење, централна, десна или лева хернија за пресек у аксијалној равни и здрав диск, Л4/Л5, Л5/С1 ниво херније у сагиталној равни). Након коришћења методе GridSearch за подешавање хиперпараметара, утврђено је да је DiscNet са следећом архитектуром дао најбоље резултате:

- конволуциони слој са 16 филтера, ReLu активационом функцијом и величином кернела 7x7,
- слој сажимања максимумом са кернелом величине 3x3,
- конволуциони слој са 32 филтера, ReLu активационом функцијом и величином кернела 3x3,
- конволуцијски слој са 64 филтера, ReLu активационом функцијом и величином кернела 4x4,
- слој сажимања средњом вредношћу,
- равни слој (енгл. *flatten layer*) (враћа копију низа трансформисаног у једну димензију),
- слој избацивања са 0.4,
- слој нормализације,
- потпуно повезан слој.

Показало се да су најоптималнији хиперпараметри:

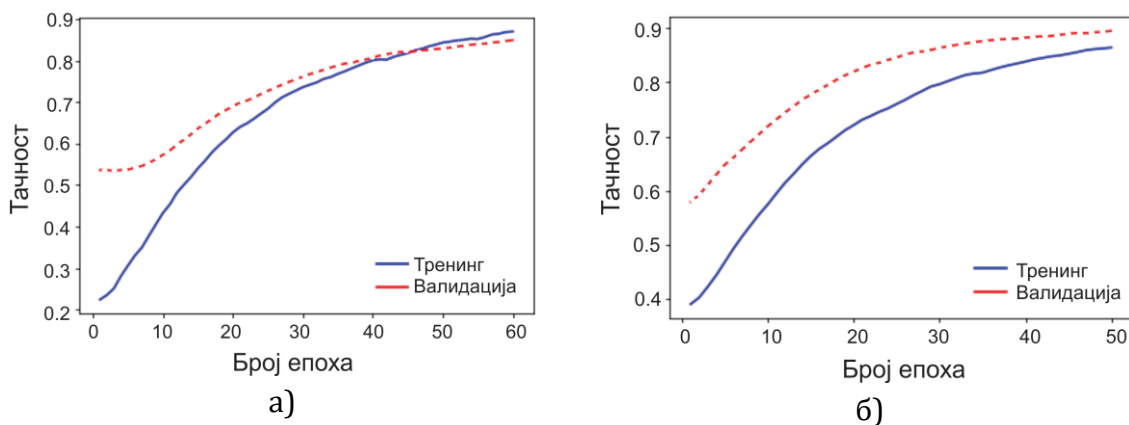
- сагитални приказ: Адам оптимизатор, брзина учења $1e-05$, $\beta_1=0.9$, $\beta_2=0.9$, $\epsilon=1e-08$
- аксијални приказ: Адам оптимизатор, брзина учења $1e-05$, $\beta_1=0.9$, $\beta_2=0.9$, $\epsilon=1e-08$

Заузетост GPU меморије и у процесу класификације је у сваком тренутку била 4% - 6% и није имала веће одступање. Пошто коначна мрежа није била тако дубока као друге предложене мреже, време обуке је било у секундама за DiscNet. Слика 5.7а приказује функцију губитка за тренинг и валидациони скуп, за аксијалну раван, док Слика 5.7б приказује функције губитка за сагиталну раван. Рано заустављање је коришћено као метод да се избегне преобучавање, као и увођење слојева избацаивања и коефицијената регуларизације.



Слика 5.7 Функција губитка за тренинг и валидациони скуп
а) аксијална раван, б) сагитална раван

Слика 5.8а и Слика 5.8б приказују криве тачности за тренинг и валидациони скуп, за аксијалну и сагиталну раван, респективно. За пресек у аксијалној равни, просечна тачност током валидације била је 0.87, макро просек је био 0.82, а пондерисани просек је био 0.87. Све три врсте тачности су пријављене због небалансираности класа. За пресек у сагиталној равни, просечна прецизност током валидације била је 0.91, макро просек је био 0.91, а пондерисани просек је био 0.91.



Слика 5.8 Функција тачности за тренинг и валидациони скуп
а) аксијална раван, б) сагитална раван

Табела 5.4 приказује детаљне резултате тачности класификације на тест подскупу на основу резултата унакрсне валидације. Просечна тачност за приказ у аксијалној равни била је 0.87 када је пет класа било класификациони задатак. Међутим, извршен је додатни задатак класификације, пошто се испупчење диска често категорише као прва фаза у којој фиброзни анулус диска остаје нетакнут и стога ова класа може представљати изазов за неуронску мрежу са аспекта разликовања од нпр. класе здравог диска. Ово се такође може уочити на основу конфузионе матрице (Слика 5.9). Након елиминисања једне класе (испупчење диска), просечна тачност се повећала за 3%. Треба напоменути да је оптимизација хиперпараметара поново извршена за четворокласну класификацију и да су најоптималнији параметри били за Адамов оптимизатор, брзина учења је $1e-04$, $\beta_1=0.9$, $\beta_2=0.9$ и $\epsilon = 1e-08$. Везано за класификацију приказа у сагиталној равни, резултати са класификацијом у три класе показали су просечну тачност од 0.91.

Табела 5.4 Тачност по класама за дијагностику диск херније (аксијални и сагитални поглед)

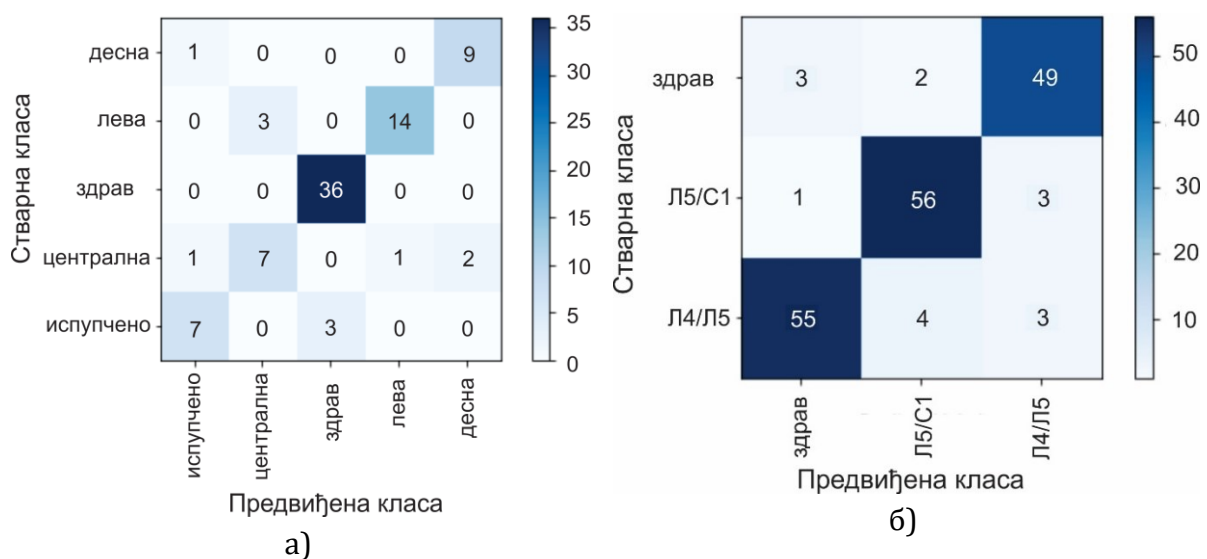
Класификација диск херније (аксијална раван) (средња вредност)

здрав 0.95±1.8	испупчен	централни	леви	десни	средња тачност класа
	0.74	0.67	0.87	0.86	0.87
здрав 1.0	-	централни	леви	десни	средња тачност класа
	-	0.73	0.82	0.90	0.90

Класификација диск херније (сагитална раван) (средња вредност)

здрав 0.90	Л4/Л5 ниво	Л5/С1 level	средња тачност класа
	0.91	0.92	0.91


Да би се узеле у обзир друге метрике осим тачности, конфузионе матрице су дате за пресек у аксијалној (Слика 5.9а), и за пресек у сагиталној равни (Слика 5.9б). За аксијални поглед, видљиво је да се класе испупчење и централна хернија често погрешно класификују, што значи да их је најтеже разликовати од других класа.



Слика 5.9 Конфузиона матрица а) аксијална раван, б) сагитална раван

Испупчење диска је у три случаја класификовано као здрав диск, што је и разумљиво, јер нема руптуре анулуса. Додатни потенцијални проблем у класификацији била је централна хернија, која је постигла најнижу тачност класификације. Ово се јавља углавном због небалансираности скупа података са малим бројем слика за централну хернију, као што је то случај и у стварној клиничкој пракси (чешће се јављају лева и десна хернија). Такође, централна протрузија се често граничи са лево/десно парацентралном протрузијом, па је разумљиво зашто је ова врста херније изазвала неке погрешне класификације (најчешће као лева или десна хернија, што приказује Слика 5.9а).

РОК криве су дате на сликама (Слика 5.10а и Слика 5.10б) за аксијалну и сагиталну раван, респективно. Може се видети да цртање праве позитивне стопе у односу на лажно позитивну стопу показује успешну класификацију.



Слика 5.10 РОК крива а) аксијална раван, б) сагитална раван

Слика 5.11а и Слика 5.11б дају криве односа прецизности и одзива (енгл. *precision recall*) за аксијалну и за сагиталну раван, респективно. Табела 5.5 приказује детаљне резултате за тест скуп, за пресек у аксијалној и сагиталној равни.


Табела 5.5 Прецизност и одзив за дијагностику диск херније (аксијална и сагитална раван)

**Класификација диск херније (аксијална раван)
(средња вредност)**

	здрав	испупчење	централна	лева	десна
прецизност	0.92	0.78	0.70	0.93	0.82
сензитивност (одзив)	1.00	0.70	0.64	0.82	0.90
специфичност	0.94	0.97	0.96	0.99	0.97
	здрав	-	централни	леви	десни
прецизност	1.00	-	0.73	0.82	0.90
сензитивност (одзив)	1.00	-	0.73	0.82	0.9
специфичност	1.00	-	0.95	0.95	0.98

	Класификација диск херније (сагитална раван) (средња вредност)		
	здрав	Л4/Л5 ниво	Л5/С1 ниво
	прецизност	0.89	0.93
сензитивност (одзив)	0.91	0.89	0.93
специфичност	0.95	0.96	0.95

Када је извршена анализа са класификацијом 4 класе, резултати су показали побољшану просечну тачност од 0.90, али и побољшану прецизност и одзив. Ово указује да постоје слике које представљају граничну линију између фаза хернијације и које ће бити предмет даљих истраживања. У сагиталној равни, прецизност и одзив су високи за све класе, те се може закључити да коришћена мрежа даје одличне резултате.



Слика 5.11 ПР крива а) аксијална раван, б) сагитална раван

Након појединачне класификације за обе равни, тестирано је колико је била успешна предложена методологија када је модел укључивао анализу на обема равнима (аксијалној и сагиталној) истовремено. Под претпоставком да су доступне слике у аксијалној и у сагиталној равни за једног пацијента, врши се тестирање модела на 100 слика које нису коришћене у фазама тренинга и валидације. Резултати показују тачност од 0.8 (Табела 5.6).

Табела 5.6 Просечни (усредњени) резултати класификације за само аксијалну раван, само сагитална раван и обе равни истовремено

Аксијална (5 класа)	Сагитална (3 класе)	Аксијална+ Сагитална
0.87	0.91	0.8

Када се упореде добијени резултати са резултатима других аутора, може се видети да већина доступних метода које се користе истражују само бинарну класификацију (здрави наспрам болесних) као што је наведено у (Zhang, Bhalerao and Hutchinson 2017), (Jamaludin, Kadir and Zisserman 2017). Радови који истражују мултикласификационе проблеме, користе само један поглед, као што је приказано у (Pan, et al. 2021) и (Salehi, et al. 2019) и постижу око 87-88% тачности на сликама у аксијалној равни. Међутим, треба рећи да је број класа коришћен у тим

истраживањима знатно мањи него у овом истраживању. Са четири класе, постигнута је већа тачност у односу на оне доступне у литератури. Такође, треба напоменути да се поређење не може вршити директно, јер се разликују класе из овог рада од класа из литературе. Ако би се извршило поређење, само у једном раду (Lu, et al. 2018) користи се анализа и класификација пресека у аксијалној и сагиталној равни, и то код стенозе кичменог канала где се постиже тачност од $80.4 \pm 1.6\%$. Табела 5.7 даје преглед најбољих објављених резултата код анализе сличних проблема. Упоредивањем претходне две табеле, може се закључити да предложени метод има низ предности са више аспеката – анализа у обе равни (аксијална и сагитална), бави се мултикласификационим проблемом на релативно малим скуповима података и постиже резултате који су упоредиви, па чак и бољи од резултата у литератури.

Табела 5.7 Преглед литературних резултата код анализе сличних проблема

	(Zhang, Bhalerao and Hutchinson 2017)	(Jamaludin, Kadir and Zisserman 2017)	(Lu, et al. 2018)		(Salehi, et al. 2019)	(Pan, et al. 2021)
<i>Истраживани проблем</i>	Стеноза кичменог канала	Стеноза кичменог канала	Стеноза кичменог канала		Диск хернија	Диск хернија
<i>Раван</i>	Аксијална	Сагитална	Аксијална+Сагитална		Аксијална	Аксијална
<i>Број слика</i>	582	12018	22796		2329	3555
<i>Бинарни / Мулти-класификациони проблем</i>	бинарни (здрави, болесни)	бинарни (здрави, болесни)	бинарни (здрави, болесни)	мулти (нормално, благо, умерено, тешко)	вишеструко (нормално, испупчење, протрузија, екструзија)	мулти (здрави, протрузија, хернија)
<i>Тачност</i>	86.6 ± 3.3	91.4	96.3 ± 0.46	80.4 ± 1.6	87 ± 7	88.76 ± 3.72

Ипак, постоји неколико ограничења која се јављају у оквиру ове анализе. Коришћени скуп података је релативно мали за дубоке конволуционе неуронске мреже и мањи је у односу на скупове података који се користе у другим студијама. Такође, скуп података је укључивао слике са нивоима протрузије, екструзије и секвестрације херније, тако да није било могуће поделити скуп података на још мање подскупе, јер је главни фокус био да се разликују нивои (Л4/Л5 или Л5/С1) и страна (испупчење, лева, десна, централна) херније. Будућа истраживања и анализе ће се концентрисати на две области: (1) усавршавање овог система коришћењем фокусирације технике која анализира одређене елементе MRI слика и (2) прикупљање више MRI слика како би се произвела потпуно аутоматска метода и софтвер за подршку одлучивању у дијагнози дискус херније.

5.1.4. Мапе активације класа

Најпре су генерисане мапе активације класа помоћу примера слика из скупа података за тестирање које су исправно класификоване (истински позитивни) и нетачно класификоване (лажно негативни) (Слика 5.12).



*Слика 5.12 Мапе активације класа за
а) тачно класификовани узорци б) погрешно класификовани узорци*

Затим су визуелизоване мапе активације класа, на основу којих може да се закључи да на тачно класификованим сликама, мапе истичу кичмену мождину у делу болесног дискуса као регион од интереса за класификацију. Оваква визуелизација потврђује тачност рада и закључивања неуронске мреже, јер су управо ови региони клинички релевантни у класификацији дискус херније. У нетачно класификованим сликама, мапе активације класа су често показивали активацију на ирелевантним областима слике као што је централни део пршљена. Ово може пружити доказе да се модел фокусира на области слике које су клинички релевантне у области компресије кичмене мождине. Поред тога, мапе активације класа треба даље анализирати да би се утврдила поновљивост, репродуктивност и осетљивост на рандомизацију тежине модела, што ће бити предмет будућих истраживања.

Иако су мапе активације класа веома илустративне у локализацији важних карактеристика у класификацији, оне имају и одређена ограничења као што је нпр. недостатак поновљивости (Merali, et al. 2021). Adebayo, et al. (2018) су показали да, када су ознаке насумично пермутиране након тренинга, мапе активације класа су и даље наглашавале делове слике које су визуелно релевантне за дијагнозу. Чак и када се ове мапе користе за анализу да би се истакле карактеристике које модел сматра релевантним за предвиђање, још увек постоје ограничења у њиховом прихватању у клиничкој пракси.

5.2. Резултати анализе биомедицинских сигнала ослањања

Главни резултати овог дела истраживања потврђују хипотезу да пацијенти код којих је потврђена дијагноза Л5/С1 диск херније имају читавања мањих вредности сила на предњем делу стопала - прстима (мање силе на левом стопалу би указивале на Л5/С1 дискус хернију на левој страни), док пацијенти са дијагнозом болести Л4/Л5 имају читавања мањих вредности сила на пети. Ови резултати се поклапају са неуролошким прегледом мишићне слабости који су обавили лекари (тест златни стандард). Систем се такође показао да је у стању да разликује здраве особе од испитаника са диск хернијом.

5.2.1. Резултати класификације

У наредним табелама приказане су различите комбинације метода нормализације комбиноване са различитим класификаторима, где је најбољи класификатор за сваки метод нормализације обележен подебљаним словима (Šušteršič, Milovanović, et al. 2020). У првом случају, за потребе унакрсне валидације, 32 пацијента су коришћена за обуку, а 1 пацијент је коришћен у сврхе тестирања (Табела 5.8). Као резултат, примењене су 33 комбинације и израчуната је средња тачност за сваки класификатор и сваку методу нормализације.

Табела 5.8 Резултати имплементираних класификатора са различитим методама нормализације на подацима када су 32 пацијента коришћена за обуку и 1 пацијент је коришћен у сврху тестирања

	Логистичка регресија	Стабла одлучивања	SVM	Наивни Бајес	K-NN	Случајне шуме
без нормализације	0.5758	0.6970	0.7273	0.7273	0.4242	0.6970
zscore	-	0.8485	0.6364	0.8485	0.3939	0.8182
norm	0.6061	0.6970	0.3333	0.6970	0.3939	0.6667
scale	0.6970	0.6061	0.6061	0.7273	0.3939	0.6667
range	0.7879	0.8485	0.5455	0.6970	0.3939	0.8788
center	-	0.7879	0.7576	0.7273	0.4545	0.7576

У другом случају, за потребе унакрсне валидације, 31 пацијент је коришћен за обуку, а 2 пацијента су коришћена у сврху тестирања. Примењено је 465 комбинација и израчуната је тачност за сваки класификатор и сваку методу нормализације. Коришћена су два начина за израчунавање тачности означена као:

- „оштра тачност“, што значи да је комбинација тестирања означена као тачна само када су оба пацијента правилно класификована (Табела 5.9),
- „средња тачност“, израчуната као средња вредност свих тачних класификација (у једној комбинацији сваки тачно класификован случај доприноси са 50% од укупне тачности). За „средњу тачност“ се такође израчунава варијанса за сваки класификатор и метод нормализације, па су стога резултати у овој табели дати као средња тачност \pm варијанса (Табела 5.10).

Табела 5.9 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 31 пацијент коришћен за обуку и 2 пацијента у сврху тестирања (тврда тачност)

	Логистичка регресија	Стабла одлучивања	SVM	Наивни Бајес	K-NN	Случајне шуме
без нормализације	0.4337	0.4621	0.5133	0.5246	0.1723	0.4602
zscore	-	0.6856	0.3977	0.6875	0.1307	0.6383
norm	0.4394	0.4716	0.1080	0.4981	0.1307	0.4678
scale	0.4716	0.3769	0.3561	0.5114	0.1402	0.3712
range	0.5549	0.7235	0.2860	0.4091	0.1307	0.6932
center	-	0.5985	0.5549	0.5208	0.1837	0.5455

За случај 2, за „средњу тачност“ израчунава се варијанса за сваки класификатор и метод нормализације, па су стога резултати у табели дати као средња тачност \pm варијанса (Табела 5.10).

Табела 5.10 Резултати имплементираних класификатора са различитим методама нормализације на сировим подацима када је 31 пацијент коришћен за обуку и 2 пацијента у сврху тестирања (средња тачност)

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације	0.653±1.556	0.687±1.653	0.715±1.527	0.722±1.4728	0.421±1.831	0.685±1.544
zscore	-	0.828±1.418	0.632±1.545	0.829±1.5197	0.382±1.706	0.810±1.556
norm	0.660±1.532	0.690±1.562	0.347±1.830	0.707±1.3903	0.382±1.706	0.676±1.623
scale	0.692±1.622	0.622±1.563	0.592±1.631	0.720±1.5088	0.389±1.764	0.629±1.529
range	0.739±1.449	0.854±1.352	0.542±1.616	0.646±1.6784	0.382±1.706	0.833±1.497
center	-	0.776±1.509	0.740±1.590	0.724±1.5559	0.449±1.925	0.752±1.663

У трећем случају, за потребе унакрсне валидације, 30 пацијената је коришћено за обуку, а 3 пацијента су коришћена у сврхе тестирања. Као резултат, примењено је 4060 комбинација и израчуната је тачност за сваки класификатор и сваку методу нормализације. Такође, коришћена су два начина за израчунавање тачности означене као „оштра тачност“ (комбинација тестирања је означена као тачна само ако су сва три пацијента која су тестирана била исправно класификована) (Табела 5.11) и „средња тачност“ (средња вредност свих тачних класификација - у једној комбинацији сваки исправно класификован случај доприноси тачности са 0.333) (Табела 5.12).

Табела 5.11 Резултати имплементираних класификатора са различитим методама нормализације на сировим подацима када је 30 пацијената коришћено за обуку и 3 пацијента у сврху тестирања (оштра тачност)

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације	0.2812	0.2727	0.3501	0.3591	0.0662	0.3116
zscore	-	0.5594	0.2427	0.5368	0.0359	0.5114
norm	0.2832	0.3050	0.0346	0.3470	0.0365	0.2964
scale	0.3121	0.2124	0.2014	0.3442	0.0444	0.2302
range	0.3941	0.6105	0.1453	0.2282	0.0365	0.5620
center	-	0.4580	0.3924	0.3567	0.0665	0.4016

Када је у питању израчунавање „средње тачности“ за овај случај, она је израчуната као средња тачност ± варијанса за сваки класификатор и метод нормализације (Табела 5.12).

Табела 5.12 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 30 пацијената коришћено за обуку и 3 пацијента у сврху тестирања (средња тачност)

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације	0.645±1.580	0.661±1.654	0.702±1.556	0.710±1.495	0.419±1.825	0.678±1.585
zscore	-	0.823±1.429	0.624±1.552	0.813±1.531	0.371±1.721	0.805±1.561
norm	0.663±1.560	0.683±1.566	0.358±1.812	0.710±1.416	0.371±1.720	0.668±1.630

scale	0.675±1.615	0.617±1.575	0.577±1.616	0.705±1.506	0.384±1.758	0.625±1.555
range	0.729±1.439	0.850±1.371	0.537±1.608	0.618±1.709	0.371±1.720	0.830±1.490
center	-	0.779±1.513	0.724±1.602	0.717±1.575	0.442±1.909	0.739±1.656

У четвртог случају, за потребе унакрсне валидације, 29 пацијената је коришћено за обуку, а 4 пацијента су коришћена у сврхе тестирања. Као резултат, примењено је 23751 комбинација и израчуната је тачност за сваки класификатор и сваку методу нормализације. И овде су коришћена два начина за израчунавање тачности означене као „оштра тачност“ (Табела 5.13) и „средња тачност“ (средња вредност свих тачних класификација - у једној комбинацији сваки исправно класификован случај доприноси 0.25 тачности (Табела 5.14).

Табела 5.13 Резултати примењених класификатора са различитим методама нормализације на подацима када је 29 пацијената коришћено за обуку и 4 пацијента у сврху тестирања (оштра тачност)

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације	0.1671	0.1630	0.2303	0.2318	0.0237	0.1987
zscore	-	0.4298	0.1438	0.4070	0.0079	0.3896
norm	0.1820	0.1903	0.0110	0.2333	0.0085	0.1927
scale	0.2092	0.1126	0.1093	0.2224	0.0122	0.1300
range	0.2752	0.5102	0.0718	0.1249	0.0085	0.4477
center	-	0.3433	0.2675	0.2347	0.0220	0.2840

Већ поменуто, за „средњу тачност“ израчунава се варијанса за сваки класификатор и метод нормализације, а детаљни резултати су приказани у табели као средња тачност ± варијанса (Табела 5.14).

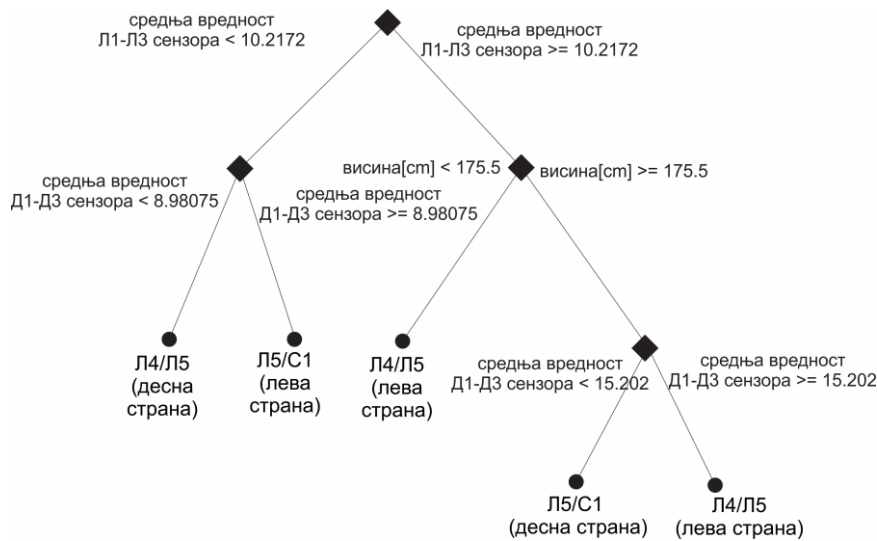
Табела 5.14 Резултати имплементираних класификатора са различитим методама нормализације на подацима када је 29 пацијената коришћено за обуку и 4 пацијента у сврху тестирања (средња тачност)

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације	0.634±1.579	0.656±1.629	0.689±1.579	0.698±1.517	0.417±1.821	0.669±1.589
zscore	-	0.811±1.458	0.614±1.556	0.799±1.542	0.361±1.733	0.798±1.567
norm	0.658±1.561	0.679±1.578	0.365±1.792	0.707±1.437	0.362±1.731	0.668±1.644
scale	0.672±1.603	0.611±1.601	0.562±1.603	0.690±1.517	0.378±1.751	0.618±1.549
range	0.718±1.447	0.844±1.382	0.531±1.605	0.603±1.722	0.362±1.731	0.826±1.502
center	-	0.778±1.527	0.708±1.614	0.707±1.587	0.435±1.896	0.734±1.665

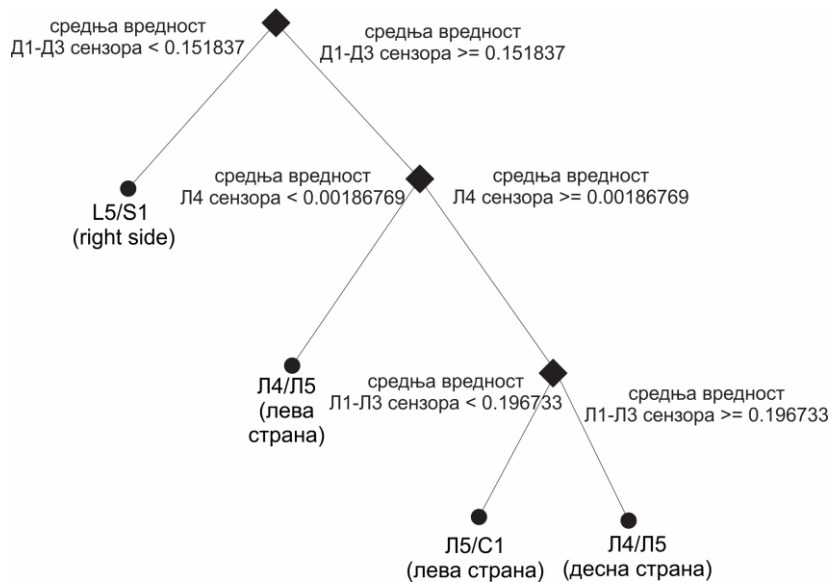
Може се приметити да је највећа тачност добијена коришћењем методом случајних шума са тачношћу од 0.8788, за случај када су 32 пацијента коришћена за обуку, а 1 за потребе тестирања. Такође, веома висока прецизност је добијена коришћењем наивног Бајеса и стабала одлучивања са тачношћу од 0.8485. Кроз све могуће комбинације, стабла одлучивања и наивни Бајес би били веома конкурентни, при чему би стабла одлучивања била боља када се користе неке

методе нормализације (*zscore*, *range* и *center*), док је наивни Бајес био бољи када није коришћена нормализација, као и када су *norm* и *scale* коришћени као методе нормализације. Ово се може објаснити чињеницом да је сам проблем заснован на логици АКО-ОНДА, што га чини погодним за ова два алгоритма. Такође, у овом тренутку, због релативно мале базе података од 33 пацијента, не могу се применити алгоритми дубоког учења.

Слика 5.13а-б приказује примере стабла одлучивања за која се показало да су погодна за анализу датог проблема. Представљено је само стабло без нормализатора и са нормализатором *range*, јер је овај нормализатор постигао најбоље резултате (Šušteršič, Milovanović, et al. 2020).



а) Стабло одлучивања – једна могућност (без нормализације)



б) Стабло одлучивања – исто стабло као у а) са *range* нормализацијом

Слика 5.13 Визуелизовани примери стабала одлучивања – приказани резултати без нормализације и нормализацијом *range*

Иако је било 9 улазних карактеристика које су коришћене као предиктори дискус херније, нису сви допринели доношењу коначне одлуке. Примарно

атрибути просечне вредности силе предњег дела стопала Л1-Л3 и просечне вредности силе предњег дела стопала Д1-Д3 су допринели доношењу коначне одлуке (Слика 5.13). Занимљиво је да нису све комбинације имале различита стабла одлучивања као резултате. На пример, када је коришћена нормализација norm, у свим комбинацијама, моделована су само 2 различита стабла одлучивања. Слика 5.13б приказује једно од ова два моделована стабла одлучивања. Овај модел је показао да је такође атрибут просечна вредност силе пете Л4 присутна као чвор одлучивања. Може се видети да бројеви који се понављају у моделованим стаблима одлука имплицирају да се проблем дискус херније може објаснити са чак 3, а не више од 6 „ако-онда“ правила. Такође је примећено да је класа, која представља Л5/С1 дискус хернију на левој страни, донекле „критична“ за дијагнозу, што се може објаснити чињеницом да је мали број пацијената био доступан у сету података са овом дијагнозом.

Пошто се метода показала добром за разликовање субјеката без дискус херније од испитаника са дискус хернијом, било је занимљиво видети како ће метод класификовати пацијенте након хируршке операције и физикалне терапије. Табела 5.15 приказује резултате за тестиране субјекте **након операције**, где ред „побољшање“ показује тачност алгоритма у поређењу са бројем пацијената са побољшаном мишићном снагом, „без побољшања“ показује тачност алгоритма у поређењу са бројем пацијената без побољшања мишићне снаге и „укупно“ показује укупну тачност када нема раздвајања на побољшано и непобољшано стање пацијента.

Табела 5.15 Резултати тестирања на пост-хируршким субјектима

	Логистичка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
	без нормализације					
побољшање	0.857	0.857	0.857	0.857	0.857	0.000
нема побољшања	0.538	0.654	0.615	0.654	0.500	0.731
укупно	0.606	0.697	0.667	0.697	0.576	0.576
	zscore					
побољшање	-	0.857	0.857	0.857	0.857	0.000
нема побољшања	-	0.654	0.654	0.654	0.462	0.654
укупно	-	0.636	0.636	0.636	0.485	0.515
	norm					
побољшање	0.857	0.857	0.857	0.857	0.857	0.000
нема побољшања	0.269	0.615	0.577	0.731	0.500	0.731
укупно	0.394	0.667	0.636	0.758	0.576	0.576
	scale					
побољшање	0.857	0.857	0.857	0.857	0.857	0.000
нема побољшања	0.423	0.615	0.538	0.538	0.423	0.654
укупно	0.455	0.606	0.545	0.545	0.455	0.515
	range					
побољшање	0.714	0.714	0.714	0.714	0.714	0.000
нема побољшања	0.615	0.731	0.692	0.692	0.462	0.731
укупно	0.606	0.697	0.667	0.667	0.485	0.576
	center					

побољшање	-	0.857	0.857	0.857	0.857	0.000
нема побољшања	-	0.654	0.731	0.692	0.500	0.769
укупно	-	0.697	0.758	0.727	0.576	0.606

Табела 5.16 приказује резултате за тестиране субјекте **након физикалне терапије**, где ред „побољшање“ показује тачност алгоритма у поређењу са бројем пацијената са побољшаном мишићном снагом, „без побољшања“ показује тачност алгоритма у поређењу са бројем пацијената без побољшања и „укупно“ показује укупну тачност када нема раздвајања на побољшано и непобољшано стање пацијента.

Табела 5.16 Резултати тестирања на испитаницима након физикалне терапије

	Логисти- чка регресија	Стабла одлучивања	Мет. пот. вектора	Наивни Бајес	К-најбл. суседа	Случајне шуме
без нормализације						
побољшање	0.722	0.722	0.722	0.722	0.722	0.000
нема побољшања	0.400	0.800	0.800	0.667	0.600	0.800
укупно	0.576	0.758	0.758	0.697	0.667	0.364
zscore						
побољшање	-	0.833	0.833	0.833	0.833	0.000
нема побољшања	-	0.600	0.533	0.467	0.333	0.533
укупно	-	0.606	0.576	0.545	0.485	0.242
norm						
побољшање	0.778	0.778	0.778	0.778	0.778	0.000
нема побољшања	0.200	0.667	0.600	0.733	0.533	0.800
укупно	0.515	0.727	0.697	0.758	0.667	0.364
scale						
побољшање	0.833	0.833	0.833	0.833	0.833	0.000
нема побољшања	0.133	0.533	0.467	0.400	0.333	0.467
укупно	0.394	0.576	0.545	0.515	0.485	0.212
range						
побољшање	0.833	0.833	0.833	0.833	0.833	0.000
нема побољшања	0.133	0.533	0.400	0.400	0.333	0.533
укупно	0.364	0.545	0.485	0.485	0.455	0.242
center						
побољшање	-	0.889	0.889	0.889	0.889	0.000
нема побољшања	-	0.667	0.733	0.733	0.600	0.867
укупно	-	0.788	0.818	0.818	0.758	0.394

Може се видети да је „побољшање“ добро дијагностиковано алгоритмом, али у зависности од метода нормализације, неки класификатори не постижу високу тачност. Најбољи алгоритми за пост-хируршку интервенцију и после физикалне терапије били су очекивано стабло одлучивања и наивни Бајес, са методом потпорних вектора као конкурентом у одређеним резултатима.

5.2.2. Креирање система за подршку одлучивању

Основна идеја је била да се систематски имплементира неколико алгоритама машинског учења као софтверских алгоритама како би се одредили најбоље прилагођени алгоритми за овај специфичан проблем. Конвенционалне методе за дијагностику дискус херније укључују различите врсте скрининга као што су рендгенски снимци, СТ, MRI или мијелограм. Ове технике су мање-више инвазивне за пацијента, укључују зрачење, а примарни недостатак је временски период проведен на листама чекања. Предложена методологија представља корак ка потпуно аутоматизованом систему који би укључивао неколико минута мерења и постављања дијагнозе на лицу места. То значи да је основни циљ да се направи неинвазивни уређај који ће помоћи лекарима при брзом почетном прегледу пацијената. Објективна мерења, заједно са методама машинског учења за класификацију нивоа дискус херније, била би помоћно средство за даљу анализу уколико се сумња на постојање дискус херније.

Иако је коришћено 9 улазних карактеристика за обуку класификатора (пол, старост, тежина, висина, просечне вредности сензора Л1-Л3, просечне вредности сензора Д1-Д3, просечне вредности сензора Л4, просечне вредности сензора Д4, тип операције (микродискектомија или дискектомија)), ниједна од горе наведених карактеристика се није показала као добар предиктор нивоа дискус херније, осим вредности сензора. То је био случај са свим комбинацијама стабла одлучивања које је приказано као најбољи класификатор. Изузетак је једно стабло одлучивања (Слика 5.13). У том случају, када није коришћена нормализација, висина особе је представљала један лист у стаблу одлуке. Међутим, у свим осталим случајевима, само вредности силе очитане са сензора су биле релевантни предиктори дискус херније (Слика 5.13б).

Када је реч о резултатима, показало се да је стабло одлучивања представља добру логику за дијагностификовање дискус херније. У већини комбинација са различитим методама нормализације, стабло одлучивања је дало највећу тачност. Када се само један субјект користи у скупу података за тестирање и у свим комбинацијама, стабло одлучивања је било најбољи класификатор када су коришћене методе *zscore*, *norm* и *center* нормализација (0.8485, 0.6970, 0.7879 тачности, респективно). Наивни Бајес је такође показао обећавајуће резултате, постигавши тачност од 0.7273, 0.8485, 0.6970, 0.7273, када се комбинује без нормализације, *zscore*, *norm* и *scale* метода нормализације. Показало се да случајне шуме постижу највећу тачност од свих алгоритама када су у комбинацији са *norm* нормализацијом, постигавши тачност од 0.8788. Даље, како се број субјеката у скупу података за тестирање повећавао (2-4 субјекта за тестирање), највећу тачност за сваку методу нормализације истовремено су постигла стабла одлучивања и Наивни Бајес (Табела 5.8-Табела 5.14). Када су 2 субјекта коришћена за тестирање, највећу тачност је постигло стабло одлучивања, заједно са методом *range* (0.7235 за „оштру тачност“ и 0.8542 за „средњу тачност“). Ово је био случај и када су 3 субјекта коришћена за тестирање, где је стабло одлучивања, заједно са *norm* нормализацијом, постигло 0.6105 „оштре тачности“ и 0.85 „средње тачности“. Поново, када су 4 субјекта коришћена за тестирање, стабло одлучивања, заједно са *norm* нормализацијом, постигло је највећу тачност - 0.5102 „тврде тачности“ и 0.8444 „средње тачности“. Уједно, стандардне девијације су биле најмање за стабло одлучивања са *norm* нормализацијом, у свим наведеним случајевима. Ово показује

да ако се подаци сензора скалирају у опсегу од [0,1], стабло одлучивања би било боље од свих осталих класификатора. Такође, ово се може верификовати увидом у статистичке метрике осетљивости, специфичности и прецизности израчунате за сваку класу, сваку поделу тренинг-тест (32-1, 31-2, 30-3 и 29-4), за сваки алгоритам и сваки метод нормализације. Ови резултати представљени су у Прилогу 1, док Табела 5.17 даје само укупне вредности за стабло одлучивања са нормализацијом *range*.

Табела 5.17 Статистичке мере – осетљивост, специфичност и прецизност за стабло одлучивања са нормализацијом *range*, у различитим комбинацијама тренинг-тест подскупова

	32 тренинг - 1 тест	31 тренинг - 2 тест	30 тренинг - 3 тест	29 тренинг - 4 тест
Сензитивност	0.8671	0.8716	0.8499	0.8578
Специфичност	0.9525	0.9541	0.9508	0.9498
Прецизност	0.8348	0.8399	0.8235	0.8302

Методе ансамбла (енгл. *Ensemble methods*) су такође тестиране, посебно Adaptive boosting, Linear programming boosting, Totally corrective boosting, Random undersampling boosting, Random subspace и Bootstrap aggregation и резултати су били или нижи или слични класичним класификаторима. У случају 32 – 1 поделе, Random undersampling boosting са 100 циклуса и максималним бројем подела од 4 је постигао тачност од 0.8788, исто као и метода случајних шума. Све остале методе ансамбла су постигле мању тачност. Слични резултати су добијени и за друге комбинације подела тренинг-тестова, и никада ансамбл методе нису постигле боље резултате у односу на класичне класификаторе. Пошто стабла одлучивања није тешко имплементирати на хардверу, мотивација да се дизајнира прилагођени чип за дијагнозу дискус херније на основу мерења силе стопала и најбољег класификатора је била оправдана. Сложеније методе ансамбла нису постигле боље резултате (најбоља тачност коју су постигли је иста тачност као и стандардни класификатори), што додатно потврђује мотивацију да се дизајнира прилагођени чип за анализу диск херније на основу „једноставног“ класификатора.

Такође треба нагласити да је логично да је вредност „оштре тачности“ опадала са већим бројем пацијената на тестирању, јер је „оштра тачност“ дефинисана кроз комбинације тестирања, као што је да се једна комбинација означава као тачна само када су сви тестирани пацијенти правилно класификовани. Ако је број тестираних пацијената био 2, то значи да само ако су оба пацијента тачно класификована, комбинација се означава као исправно класификована. Ово постаје веома тежак задатак ако је број испитаника 2, 3, 4 или већи, јер је комбинација означена као класификована само ако су сви субјекти тестирања правилно класификовани. Врло је вероватно да ће један пацијент бити погрешно класификован и због тога ће све комбинације са тим пацијентом бити „нетачне“. Стога „средња тачност“ представља бољу метрику, јер даје средњу вредност свих тачних класификација (у једној комбинацији сваки исправно класификован случај доприноси одређеном проценту тачности). Међутим, идеја је била и да се прикаже „оштра тачност“ да би показали да, чак и уз строга правила, тачност не пада испод 50% за најбољи класификатор.

Добијена је слаба корелација између пола и нивоа дискус херније, као и између типа гојазности и нивоа дискус херније (коэффициенти корелације су 0.279 и 0.037, респективно, без статистичке значајности). Пошто није постојала јака веза између било које од ових варијабли, може се закључити да није било преференције у погледу типа гојазности и одређеног нивоа дискус херније, или пола и одређеног нивоа дискус херније.

Време за обуку у најлошијем сценарију, када је за обуку коришћено 29 пацијената и када су израчунате све могуће комбинације, са једном методом нормализације и свим класификаторима, било је око 7 сати. Време извођења закључивања је испод једне секунде, па се може се тврдити да се време обуке може смањити оптимизацијом коришћењем боље компјутерске или GPU конфигурације.

Приликом експеримента примећено је да нека мерења нису била адекватна, што значи да стопало није било добро постављено на сензоре (тј. није успевало да покрије сензоре), и због тога је дошло до читавања вредности близу нуле за те сензоре. Овакав случај се јавио код 3 пацијента што би потенцијално могло довести до лажних резултата који указују на присуство дискус херније. Да би се превазишао овај проблем, примењен је исти концепт и методологија на 30 пацијената, што значи да су уклоњена 3 потенцијално лоша мерења из скупа података. Поновљен је исти процес поделе на подскупе за тренинг и тест на 29 и 1, 28 и 2, 27 и 3, 26 и 4, респективно. Резултати су показали да је тачност већа за чак 10-20% када није коришћена нормализација. Међутим, када су подаци нормализовани коришћењем било ког нормализатора, тачност се побољшала до 4%. Поред тога, примећено је да стабло одлучивања у овом случају у свим комбинацијама више личи на пример приказан на слици (Слика 5.13б), него на пример приказан на слици (Слика 5.13а), што значи са мање чворова. Све ово имплицира да се са више мерења може да направи једноставан систем за подршку одлучивању са само три АКО-ОНДА правила. Прилагођавање стопала платформи и сензорима може представљати ограничење тренутног дизајна платформе, тако да ће се он у будућности ажурирати како би могао да подржи неколико позиција сензора који зависе од стандардне величине ципеле/стопала (као што је покретна шина/вођица дуж линије фиксних сензора – једна шина вођица за три метатарзална сензора и једна шина за вођење за сензор пете).

Што се тиче поређења резултата ове докторске дисертације са радовима других аутора, у радовима (Hancock, et al. 2011), (Suri, et al. 2011) и (McCarthy, et al. 2007) се истражује неуролошка веза између нервних корена и дерматома. Анализе у оквиру ових студија су рађене само са медицинског становишта, и то у виду студија случаја и са аспекта оправданости употребе слабости мишића у дијагностици дискус херније и сличних проблема са кичмом. Са изузетком неколико радова наше истраживачке групе (Peulić, Šušteršič and Peulić 2018, Šušteršič, et al. 2020, Peulić, et al. 2020), не постоје радови који се баве имплементацијом алгоритама вештачке интелигенције на сигнале сензора силе стопала у циљу дијагностиковања дискус херније на нивоима Л4/Л5 и/или Л5/С1. Ови радови се првенствено баве презентацијом нове платформе коју су осмислили аутори (Peulić, Šušteršič and Peulić 2018, M. S. Peulić 2020), затим се истражује статистичка значајност вредности сензора у поређењу са клиничким мануелним тестом мишића (Peulić, et al. 2020), како би се створио систем ране идентификације дискус херније који би представљао помоћно средство лекарима да пошаљу тестиране пацијенте на даље испитивање (Šušteršič, et al. 2020). Ниједно друго

истраживање није изградило платформу за објективно мерење слабости мишића и доношење одлуке засноване на машинском учењу о нивоу и страни диск херније. Све друге аутоматске методе се баве MRI скенирањем и покушавају да предвиде закључак о стању пацијента на основу сегментације слике (Handayani 2019) (Schmidt, et al. 2007) (Corso 2008) (Neubert, Fripp and al 2012). Главно ограничење ових студија је то што су све примењене методе полуаутоматске и захтевају додатну корекцију решења или су веома осетљиве на промене параметара. На основу већ поменутог да су истраживања показала да вероватноћа догађаја хернијације лумбалног диска, на основу позитивног налаза MRI је само 8% (Trafimow and Trafimow 2016), разумљиво је да се MRI скенирање не може користити као једини извор дијагностичких информација. Све наведено представља добру основу за развој нове методе за аутоматско откривање диск херније ван MRI анализе, што је и приказано у овој дисертацији.

Даља истраживања у овој области могу се усмерити ка имплементацији алгоритама који су у овом раду показали највећу тачност (тј. стабла одлучивања) на јефтиним чиповима како би се створио истински преносив систем, специфичан за болест (диск хернија) који може послужити као систем за подршку одлучивању за брзу дијагностику чак и код куће, ван болница и медицинских центара. Ово ће у великој мери смањити редове чекања за MRI, који је, а вероватно ће и остати златни стандард у овој области.

Главна ограничења овог истраживања произилазе из малог броја доступних пацијената, као и због тога што је понекад долазило до грешака у мерењу јер сензори нису били добро прилагођени да одговарају стопалима пацијента. Овај недостатак се може превазићи у следећој генерацији платформе са више положаја сензора који ће зависити од величине стопала/ципеле. На тај начин ће се избећи позиционирање одређено за сваки субјект понаособ и уместо тога дозволиће се положаји сензора на основу величине стопала. Будућа истраживања ће се фокусирати на креирање мерне платформе повезане са процесорским чипом независно од рачунара/лаптопа, како би се омогућио прави систем мерења на лицу места са системом за подршку одлучивању о дискус хернији у реалном времену.

6. ИМПЛЕМЕНТАЦИЈА АЛГОРИТАМА ЗА ДИЈАГНОЗУ ДИСКУС ХЕРНИЈЕ НА ФПГА ЧИПУ

Недавно су се алгоритми за обраду слике имплементирани на хардверу појавили као најизводљивије решење за побољшање перформанси система за обраду слике. Увођење реконфигурабилних уређаја и хардверских програмских језика додатно су убрзали обраду слика на хардверу. ФПГА је програмабилни (или реконфигурабилни) уређај у којем се коначна логичка структура може директно конфигурисати од стране крајњег корисника (Brown, et al. 1992). ФПГА се састоји од низа неповезаних елемената који се могу програмирати или међусобно повезати (или конфигурисати) према спецификацији корисника на теоријски неограничен број начина. С обзиром да се може репрограмирати и лако надоградити, ФПГА нуди компромис између флексибилности процесора опште намене и хардвера брзина ASIC (Mittal, Gupta and Dasgupta 2008). Стога се ФПГА често користи као платформа за имплементацију алгоритама за обраду слика у реалном времену.

Избор архитектуре система за имплементацију хардвера укључују стандардне ћелије ASIC-а, али и програмабилна решења као што су дигитални процесори сигнала ДСП (енгл. *digital signal processor (DSP)*) и ФПГА. Сваки од њих има предности и недостатке. Потпуни прилагођени ASIC дизајн може да понуди најбоље перформансе, али се не може реконфигулисати. Стога, било каква грешка у дизајну хардвера која постоји након производње подразумева одбацавање целог производа. ДСП су специјализовани микропроцесори, обично програмирани у програмском језику C, или у асемблерском коду ради остваривања побољшаних перформанси. Добро су прилагођени за изузетно сложене и математички интензивне задатке као што је обрада слика. И даље је потребно познавање хардверског дизајна, али је његова предност што је крива учења много бржа у поређењу са другим дизајнерским изборима. Међутим, моћни ДСП-ови су скупи и њихове одговарајуће софтверске апликације некада не одговарају перформансама хардвера. Реконфигурабилна рачунарска технологија код ФПГА, заједно са многим другим карактеристикама ФПГА чине идеалним за обраду слика у реалном времену (Mittal, Gupta и Dasgupta 2008). Предности као што су паралелизам и технике цевовода (енгл. *pipeline techniques*) могу бити развијене на ФПГА, што није могуће код наменских ДСП-а (Xilinx 2002). Главни разлог за већину инжењера зашто изабрати ФПГА у односу на ДСП јесу микропроцесорски захтеви апликације (Mittal, Gupta и Dasgupta 2008).

Многе предности које има ФПГА чине их пожељним избором за имплементацију у домену дигиталне обраде слика. На основу истраживања (Mittal, Gupta и Dasgupta 2008), основне карактеристике, које су уједно и предности ФПГА су:

1. Карактеристика многих проблема који се јављају у области обраде слика је пре свега вишеструка итеративна обрада скупова података (нпр. четворостепена детекција ивица помоћу Canny методе), што захтева вишеструке прелазе преко слике. Ови прелазни, који се морају изводити један за другим на рачунару опште намене, могу се спојити у један пролаз на ФПГА, јер његова структура може да искористи просторни и временски

паралелизам. ФПГА може да ради са више прозора паралелно, као и да паралелно извршава вишеструке операције унутар једног прозора.

2. Примена неколико техника оптимизације као што су *Loop Fusion*, *Loop Unrolling* итд. омогућава ефикасно коришћење ФПГА ресурса и убрзање избегавањем сувишних операција.
3. ФПГА су способне за паралелни И/О, што омогућава да обављају читање (из меморије), обраду и писање (у меморију) истовремено. Многе операције као нпр. конволуција, проналажење квадратног корена итд. много брже се изводе коришћењем методе цевовода и паралелизма.
4. Сва логика на ФПГА може се поново реконфигурисати, креирајући потпуно другачији дизајн. Ова врста архитектуре омогућава велику различитост логичких дизајна у зависности од ресурса процесора, који се могу заменити за нови дизајн, чим се уређај репрограмира.
5. ФПГА пружа флексибилност за репрограмирање и надоградњу на нове стандарде. Лака могућност надоградње осигурава да се ФПГА решења брзо развијају без ризика од застарелости.
6. Поновна употреба и ефикасност хардвера имплементираних на ФПГА, посебно је корисна у развоју интелектуалне својине обраде слике (енгл. *intellectual property- IP*) што омогућава ефикасан систем у погледу трошкова и перформанси. Могућност брзе интеграције IP блокова без потребе за модификацијом или понављањем циклуса верификације, поједностављује отклањање грешака и на тај начин у великој мери смањује време до пуштања на тржиште.
7. Због своје архитектуре засноване на LUT-у (енгл. *look-up-tables (LUT)*), неки кернели конволуције (као што је нпр. константни коефицијент мултипликатор) могу се врло ефикасно имплементирати.
8. Висока густина израчунавања на ФПГА заједно са ниским трошковима развоја омогућава да чак и најмање потрошачко тржиште може да сноси трошкове развоја ФПГА. У ствари, у поређењу са ASIC, ФПГА су посебно корисни у апликацијама мањег обима.
9. Широки спектар ФПГА доступних путем разних компанија као што су Xilinx, Altera, итд. испуњавају захтеве за примену у бројним апликацијама (Mittal, Gupta и Dasgupta 2008).

С друге стране, постоје и одређена ограничења ФПГА за примену у области обраде слика:

1. Тренутно постоји много трошкова у самом дизајну ФПГА. Ово укључује време преноса података које је потребно за отпремање/преузимање података из/на процесор који се може реконфигурисати на/са хоста, односно време за реконфигурацију.
2. ФПГА су одличан избор само за алгоритме који не користе формат са покретним зарезом или сложену математику. Дељење и множење су нпр. веома сложени и скупи на ФПГА. Дакле, дизајнери морају да преформулишу своје алгоритме и избегавају сложене математике операције (нпр.


имплементација дељења са 9 се избегава, већ се врши дељење са 8 користећи методу шифтовања битова).

3. Величина меморије која се може имплементирати помоћу стандардне логичке ћелије на ФПГА је ограничена, а имплементација меморије је неефикасна употреба ФПГА ресурса.
4. Рутине у којима се сложени задаци не могу поделити на једноставније задатке морају се обављати више на серијски начин, који није сасвим ефикасан на ФПГА.
5. Хардвер нуди много већу брзину извршавања од софтверске имплементације, али то долази са ценом повећаног времена развоја, што је карактеристично за развој на хардверу. Већина софтверских дизајнера ради у програмском језику C, али да би се развио хардверски систем, неопходни програмски језици су VHDL или Verilog, или се користи софтверско-хардверско повезивање шема конверзије, као што је Streams-C, која претвара C код у VHDL, или MATCH, који претвара Matlab код у VHDL (Mittal, Gupta и Dasgupta 2008).

6.1. Имплементација Наивног Бајеса алгоритма на ФПГА чипу

Због једноставности алгоритма наивног Бајеса и могућности развоја система за дијагностику дискус херније са радом у реалном времену, укључујући аквизицију, обраду и одлучивање, ФПГА представља одлично решење. Такође, реконфигурабилност ФПГА омогућава тестирање различитих алгоритама, где би коначан избор крајњег алгоритма био имплементиран као дизајниран чип у систему подршке одлучивању дијагнозе дискус херније.

Развијени систем за дијагнозу дискус херније подразумева претходно описану методологију која користи плочу са сензорима на метатарзалним главама и петама стопала. Када индикаторска лампица потврди да систем ради и да је спреман за употребу, прекидач се укључује како би почело мерење. Као што је раније поменуто, када испитаник стоји на платформи, мерења се снимају у одређеном временском периоду, након чега пацијент треба да промени положај тако што ће стајати на предњем делу стопала (стајање на прстима), а затим поново на петама. Подаци прикупљени током три репрезентативна стајања коришћени су за постављање дијагнозе и након тога за лечење. Време мерења није било унапред дефинисано, већ је снимање трајало све док три карактеристична положаја нису била снимљена. Ово је било неопходно јер пацијенти понекад нису имали стабилан положај, тј. нису били у стању да одрже равнотежу на предњем делу стопала /петама итд. Слика 6.1 представља шематски приказ описаног система и методологију за дијагностику дискус херније укључујући и имплементацију на ФПГА чипу. Претпоставка је да ће у зависности од нивоа дискус херније доћи до слабости мишића у ножним прстима. Ако је диск компромитован на нивоу L4/L5, јавиће се мишићна слабост у петама пацијената, док ће компромитовање диска на нивоу L5/S1 утицати на слабост мишића у прстима стопала. Ове претпоставке се користе за креирање система мерења заснованог на мерној платформи и сензорима за мерење сила приликом стајања пацијента на платформи. Прикупљени сигнали се прослеђују на ФПГА, где је имплементирана наивна Бајесова логика, да би се извршила коначна дијагноза о нивоу и страни дискус херније.



Слика 6.1 Шематски приказ креираног система за дијагностику дискус херније

У наставку рада прво ће бити описан алгоритам Наивног Бајеса за софтверску имплементацију, након чега је објашњено на који начин је овај алгоритам имплементиран на ФПГА чипу, а на крају су приказани резултати који су добијени софтверски/хардверски.

6.1.1. Алгоритам Наивног Бајеса за софтверску имплементацију

За потребе препроцесирања сировог сигнала, у овој докторској дисертацији је спроведено филтрирање сировог сигнала *median* филтером (енгл. *median filter*). Додатно, филтрирани сигнал је коришћен за издвајање делова сигнала који одговарају периоду ослањања на предњем делу стопала и периоду ослањања на пети. Вредности из ових периода су затим усредњене, тако да су креирани улази у систем за анализу:

- просечна вредност Л1-Л3 предњег дела стопала,
- просечна вредност Д1-Д3 предњег дела стопала,
- просечна вредност пете Л4 и
- просечна вредност пете Д4.

На основу већ описаних претпоставки о мишићној слабости и издвојених атрибута, примењује се наивна Бајесова теорема. То се чини, јер иако логика о директној вези слабости мишића и дијагнозе постоји, може се десити да се чак и пацијентима са нижим вредностима силе ослањања на пети дијагностикује Л5/С1 дијагноза, па се примењује Бајесова теорема како би се израчунале све потребне вероватноће.

Бајесова теорема је дефинисана као:

$$P(c_k | x_1, x_2, x_3, \dots, x_n) = \frac{P(c_k) \times P(x_1, x_2, x_3, \dots, x_n | c_k)}{P(x_1, x_2, x_3, \dots, x_n)} \quad 6.1$$

где је:

- $P(c_k | x_1, x_2, x_3, \dots, x_n)$ - условна вероватноћа класе датог предиктора (атрибута),
- $P(c_k)$ - априори вероватноћа класе,
- $P(x_1, x_2, x_3, \dots, x_n | c_k)$ - условна вероватноћа атрибута за дату класу,
- $P(x_1, x_2, x_3, \dots, x_n)$ - априори вероватноћа атрибута.

У случају класификације дискус херније, дијагнозе су независне једна од друге, јер код пацијената може да се јави вишеструка дискус хернија, што значи да хернијација на једном нивоу не утиче на појаву херније на другом нивоу (Reyentovich and Abdu 2002). Ово доводи до претпоставке о независности између атрибута:

$$P(x_1, x_2, x_3, \dots, x_n | c_k) = \prod_{i=1}^n P(x_i | c_k) \quad 6.2$$

Коначно, да би се утврдила коначна дијагноза, уобичајено је правило, које се такође користи у овој дисертацији, а то је да се изабере хипотеза која је највероватнија и која се зове максимално апостериорно правило одлуке:

$$output = argmax \left(P(c_k) \times \prod_{i=1}^n P(x_i | c_k) \right) \quad 6.3$$

Због чињенице да су подаци добијени са сензора континуални, користи се нормална дистрибуција нумеричке променљиве. Када предиктори имају континуалне вредности и нису дискретни, претпоставља се да су ове вредности узорковане Гаусовом дистрибуцијом. Пошто се облик вредности присутних у скупу података мења, формула за условну вероватноћу се мења и дефинишу је два параметра (средња вредност (једн. 6.5) и стандардна девијација (једн. 6.6)):

$$P(X_i = x | c_k) = \frac{1}{\sqrt{2\pi\sigma_{ik}}} e^{-\frac{(x-\mu_{ik})^2}{2\sigma_{ik}^2}} \quad 6.4$$

$$\mu_{ik} = \frac{1}{n} \sum_{i=1}^n x_{ik} \quad 6.5$$

$$\sigma_{ik} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{ik} - \mu_{ik})^2} \quad 6.6$$

Да би се утврдило да ли је испитаник здрав или са диск хернијом, тестира се да ли вредности силе на предњем делу оба стопала показују разлике веће од мерног

threshold-а (исто се проверава за вредности силе пете на оба стопала). У случају да су ове разлике мање од мерног *threshold*-а, субјект се категорише као здрав, у супротном започиње фаза тестирања применом Бајесове теореме описане у секцији 6.1.1. Мора се нагласити да је фаза обуке применом Бајесове теореме завршена пре тестирања субјектата. Тренирање и тестирање се изводе користећи ФПГА (засновано на хардверу) и Матлаб (засновано на софтверу), а резултати се затим упоређују. То значи да се израчунавање свих потребних вероватноћа (априорне и постериорне вероватноће дате једначинама 6.1-6.6) врши и хардверски и софтверски како би се обезбедило да се резултати на тест подскупу могу адекватно упоредити.

6.1.2. Методологија имплементације Наивног Бајеса на ФПГА чипу

Описана Бајесова теорема за дијагностику дискус херније је имплементирана као VHDL код (енгл. *VHSIC hardware description language*) помоћу Vivado 2016.4. Да би се бројеви користили у реалном формату, увезена је библиотека *IEEE.MATH_REAL.ALL*. Додатно, за читање из датотеке увози се пакет *std.textio.all*. Једначина 6.5 је коришћена за израчунавање средње вредности датог атрибута (нпр. предње лево стопало), док се помоћу једначине 6.6 израчунава стандардна девијација. Обе вредности се користе у једначини 6.4, где се вероватноћа да се пацијенту дијагностикује један тип дискус херније израчунава на основу средње вредности и стандардне девијације.

Како је база обухватала укупно 33 пацијента, 29 пацијената је послужило као инстанца за обуку алгоритма, а 4 пацијента као тест инстанце. Процес учитавања из датотеке се врши истовремено са израчунавањем средње вредности и вредности стандардне девијације. Првих 29 података односи се на атрибут 1 (просечне вредности стајања на прстима леве ноге). Сваки број у овом опсегу је уписан у сигнал *"attribute1_sig"*. Такође, једна привремена променљива *"temp"* се користи за сумирање свих прочитаних вредности из датотеке. За сваку дијагнозу, нпр. L4/L5 са десне стране („L4/L5_right“), сваки атрибут садржи четири вредности (један узорак је искључен јер се користи у сврхе тестирања), па када се четврта вредност упише у сигнал „attribute1_sig“, средња вредност се израчунава за случај „L4/L5_right“. Следећа дијагноза је „L5/S1_right“ и следећих 11 података сензора се односи на ову дијагнозу. Када се прочита 15-та вредност, треба израчунати и средњу вредност за ову врсту болести. Након што се прочита последња вредност која се односи на атрибут 1, биће доступна средња вредност за сваку дијагнозу, након чега је могуће израчунати и стандардну девијацију за сваки случај. Ово се ради коришћењем израчунате средње вредности, сабирањем квадратне разлике између учитане вредности из атрибута и израчунате средње вредности. Затим се збир подели бројем вредности учитаних из атрибута (за сваку болест посебно) минус један (n-1). Принцип је потпуно идентичан за сваки од доступних атрибута само праћењем индекса за почетак и крај атрибута – подаци за атрибут 2 (прсти десно) су између 29. и 57. позиције, подаци за атрибут 3 (пета лево) су између 58. и 86. позиције, док се податак са 86. позиције односи на последњи, атрибут 4 (пета десно).

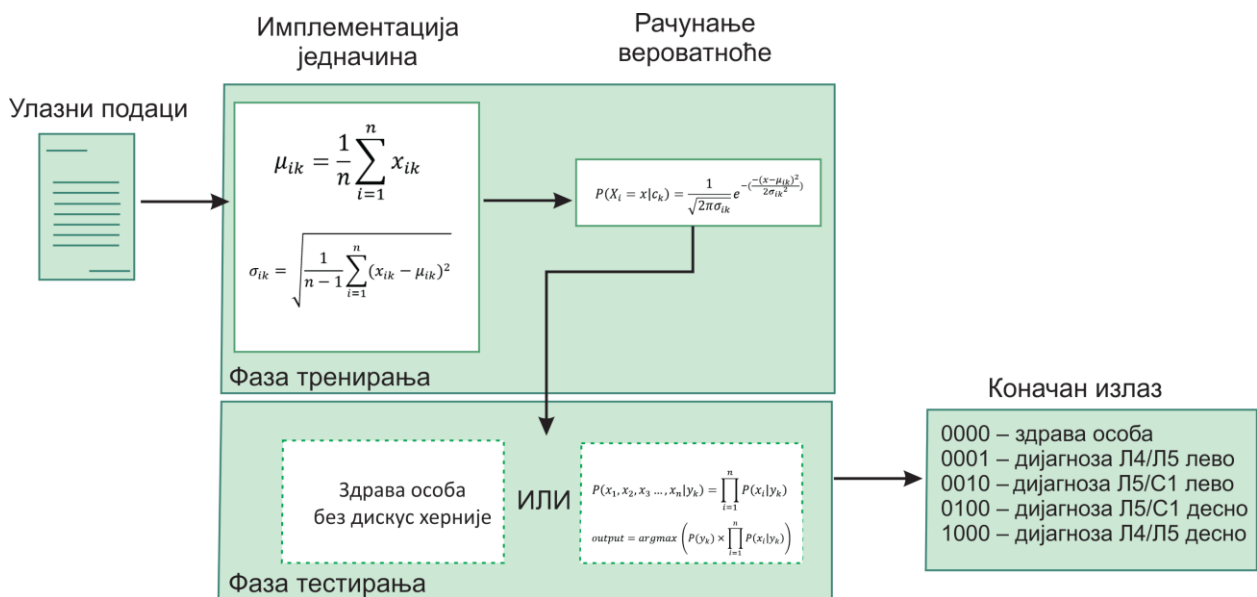
Након израчунавања захтеване средње вредности и вредности стандардне девијације, потребно је израчунати појединачне условне вероватноће за сваки атрибут, обзиром на болест (једн. 6.4). За сваки тест случај креира се низ дужине 16. Прве четири вредности у овом низу се односе на вероватноћу да пацијент има

дијагнозу „L4/L5_right“, следеће четири вредности се односе на „L5/S1_right“, затим на „L5/S1_left“ и на крају „L4/L5_left“. Коначно, априори вероватноће за обољење се затим комбинују са условним вероватноћама да би се формирала коначна вероватноћа (једн. 6.1).

Сигнали под називом „P“ служе да покажу резултате дијагностике („L4/L5_right, L5/S1_right, L5/S1_left, ili L4/L5_left“) на тест случајевима – кодирани као четворобитне вредности где место са вредношћу 1 одговара одређеној болести, а на осталим местима се налази вредност 0. Установљена је следећа нотација:

- 0000 – здрав испитаник
- 0001 – дијагноза L4/L5_left
- 0010 – дијагноза L5/S1_left
- 0100 – дијагноза L5/S1_right
- 1000 – дијагноза L4/L5_right

Одлука да ли се болест испојила је заснована на једначини 6.3. У сврху тестирања, сваком од 4 тестирана пацијента дијагностикован је различит ниво дискус херније (по један представник за сваку дијагнозу). На основу израчунатих вероватноћа, врши се доношење одлуке и четворобитне нотације се чувају у променљивим P1-P4. Слика 6.2 представља блок дијаграм тока за дијагностику дискус херније на ФПГА, који укључује претходно описану методологију.



Слика 6.2 Шематски дијаграм тока за дијагностику дискус херније на ФПГА

6.1.3. Резултати имплементације Наивног Бајеса на ФПГА чипу

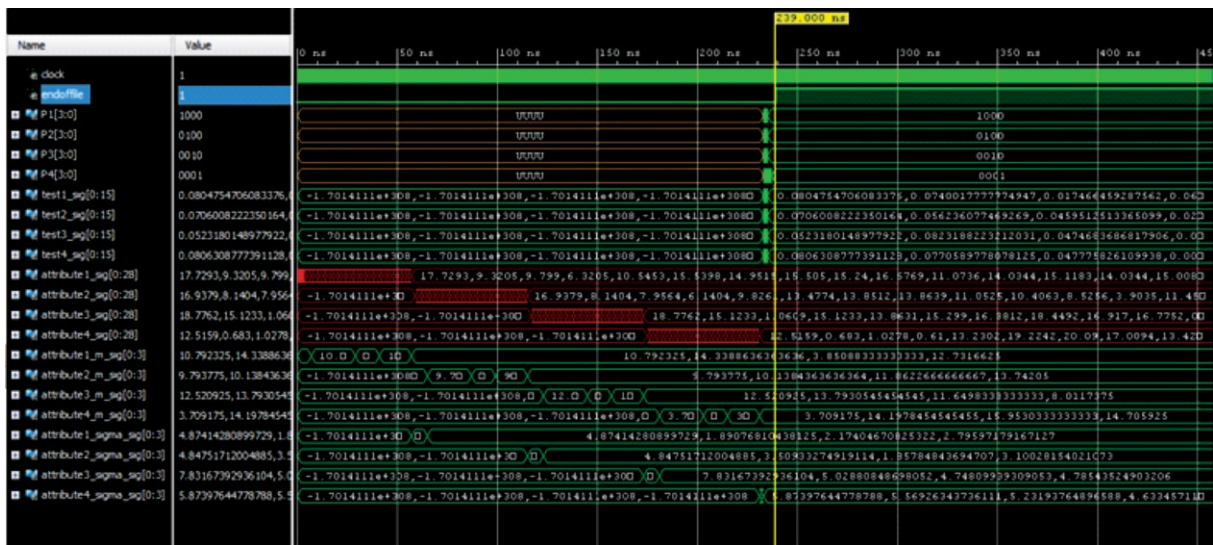
Главни резултати ове анализе показују да пацијенти којима је дијагностикована L5/S1 дискус хернија имају слабија читавања за силе ослањања на предњем делу одговарајућег стопала (што значи да ако је лева страна, онда ће силе на левом стопалу бити слабије), док пацијенти са L4/L5 дијагнозом имају слабија читавања за силе ослањања на одговарајућој пети стопала. Успостављен систем је такође у стању да препозна здраве субјекте или открије побољшања стабилности пацијената (мишићне јачине) након операције или физикалне

терапије. Резултати који су добијени су у складу са златним стандардом – неуролошким прегледом мишића.

Априорне вероватноће класе израчунате за скуп за тренинг биле су:

- $P(L4/L5 \text{ left side}) = 0.276$
- $P(L4/L5 \text{ right side}) = 0.207$
- $P(L5/S1 \text{ left side}) = 0.138$
- $P(L5/S1 \text{ right side}) = 0.379$

Резултати који се односе на саму симулацију су логични – прво се врши читање атрибута из датотеке. Затим, када променљива *endoffile* добије вредност 1, значи да је читање завршено (жути маркер показује одговарајуће место). Променљиве *attribute1_sig* до *attribute4_sig* (обојене црвеном бојом) су атрибути који се читају из датотеке и које улазе у даље израчунавање (Слика 6.3).



Слика 6.3 Резултати симулације имплементираниог експертског система са приказаним свим главним сигналина

Остатак сигнала се такође може видети у резултатима симулације представљеним на следећој слици (Слика 6.4), са израчунатим средњим вредностима (*attribute1_m_sig* до *attribute4_m_sig*), и израчунатим вредностима стандардне девијације (*attribute1_sigma_sig* до *attribute4_sigma_sig*). Коначни резултати се чувају у варијаблима "P1, P2, P3, P4". Променљива „P1“ треба да садржи бинарни код „1000“ јер је тест пример из групе са дијагнозом „L4 /L5_right“, променљива „P2“ треба да садржи бинарни код „0100“ јер је тест пример дијагнозе „L5/S1_right“, променљива „P3“ код „0010“ јер представља тест пример дијагнозе „L5/S1_left“, и на крају променљива „P4“ треба да садржи бинарни код „0001“ који се односи на дијагнозу „L4/ L5_left“ (Слика 6.4).



Слика 6.4 Резултати описаног експертског система за дијагностику дискус херније имплементираниог на ФПГА

Када се упореде резултати добијени симулацијама на ФПГА (Табела 6.1) и извршавањем у Матлаб-у (Табела 6.2) за подскуп теста, може се приметити да се

постиже веома добро поклапање. Ово је разумљиво, пошто се користи библиотека *IEEE.MATH_REAL.ALL*. Такође, резултати из табеле потврђују претпоставку и правила која је дефинисао лекар у погледу смањене функције мишића на појединим деловима стопала (предњи део стопала или пете) и одговарајући ниво дискус херније. Највеће вероватноће за сваку дијагнозу су дате подебљаним словима у наредним табелама (Табела 6.1 и Табела 6.2). Испод броја тестираних пацијената, у заградама су дате дијагнозе које представљају златни стандард.

Табела 6.1 Излазне вероватноће за четири различита пацијента, сваки са различитом дијагнозом (резултати ФПГА симулације)

Предвиђена дијагноза	Тест пацијент бр. 1 (L4/L5_right)	Тест пацијент бр. 2 (L5/S1_right)	Тест пацијент бр. 3 (L5/S1_left)	Тест пацијент бр. 4 (L4/L5_left)
L4/L5_left	1.000e-08	1.984e-07	3.060e-07	2.290e-05
L4/L5_right	8.774e-07	7.452e-07	3.180e-07	3.349e-07
L5/S1_left	1.328e-10	4.800e-12	1.110e-05	1.012e-07
L5/S1_right	6.100e-09	1.550e-05	4.347e-09	1.118e-05

Табела 6.2 Излазне вероватноће за четири различита пацијента, сваки са различитом дијагнозом (резултати Матлаб симулације)

Предвиђена дијагноза	Тест пацијент бр. 1 (L4/L5_right)	Тест пацијент бр. 2 (L5/S1_right)	Тест пацијент бр. 3 (L5/S1_left)	Тест пацијент бр. 4 (L4/L5_left)
L4/L5_left	9.930e-09	1.141e-07	2.300e-07	1.804e-05
L4/L5_right	8.786e-07	7.117e-07	3.182e-07	3.363e-07
L5/S1_left	1.428e-10	4.831e-12	1.484e-05	1.026e-07
L5/S1_right	6.123e-09	1.439e-05	4.372e-09	1.191e-05

Сва четири субјекта тестирања су исправно дијагностификована помоћу Матлаб и ФПГА симулација. Мора се нагласити да испитанике није било једноставно дијагностиковати, јер су имали сличне вредности појединих сила, односно за тест пацијента бр. 4, просечне силе су биле 11.6434, 11.5554, 9.7108, 15.7851 за предњи део на левом стопалу, предњи део на десној ноzi, пети на левом стопалу и пети на десном стопалу, респективно. Ово показује да је предложени систем који користи Бајесову теорему адекватан за дијагностику дискус херније.

Укупно време за анализу и добијање резултата у ФПГА симулацији износило је 240 ns, што гарантује анализу у реалном времену. Матлаб је са друге стране анализирао исте податке за просечно 0.047222s. Рапортирано време укључује и обуку и фазу тестирања. Фреквенција такта је била 100 MHz.

Што се тиче дијагнозе побољшања стабилности код субјеката након операције/после физикалне терапије, успостављени метод је детектовао 7 пацијената од 33 као здраве након операције и 18 пацијената од 33 као здраве након физикалне терапије. Исте резултате је потврдио и доктор користећи неуролошки преглед (златни стандард). Детаљније објашњено, за постоперативно стање, 7 пацијената је класификовано као здраво, 22 је исправно дијагностиковано (што значи да је дијагноза иста као у преоперативном стању) и 4 пацијента су погрешно класификована (различита дијагноза од преоперативног стања). За стање после физикалне терапије, 18 пацијената је класификовано као здраво, 10 је исправно дијагностиковано (што значи да је дијагноза иста као у преоперативном стању) и 5

је погрешно класификовано (тј. успостављена је различита дијагноза од преоперативног стања). То доводи до закључка да је тачност система 87.87% за постоперативно стање и 84.84% за стање након физикалне терапије.

Сви погрешно класификовани пацијенти су настали због грешке у мерењу, што значи да сензори вероватно нису били добро прилагођени стопалима пацијента, а што је довело до тога да су неке вредности веома близу нуле, иако заправо нису биле нуле. Ти пацијенти нису искључени из анализе, обзиром на то да је само за 33 пацијента била доступна документација са комплетним прегледом (преоперативно, постоперативно и мерење после физикалне терапије). Овај систем за подршку одлучивању вероватно да не може у потпуности да замени ручно тестирање мишића које врши лекар и које се тренутно користи као златни стандард, али може да се користи као потврда лекарској дијагностици о слабости мишића и као помоћ у постављању дијагнозе дискус херније. Пошто је скуп података прилично мали, врши се унакрсна валидација заснована на софтверу, независно од ФПГА хардвера. Ово се ради на тај начин што се изводе све комбинације већ описаних подела тренинг-тест пацијената:

- 32 пацијента коришћена су за тренинг и 1 пацијент је коришћен за тест,
- 31 пацијент коришћен је за тренинг и 2 пацијента су коришћена за тест,
- 30 пацијената је коришћено за тренинг и 3 пацијента су коришћена за тест и
- 29 пацијената је коришћено за тренинг и 4 пацијента су коришћена за тест.

Табела 6.3 Резултати унакрсне валидације (средња тачност \pm варијанса)

Тренинг тест комбинација	Тачност
32-1	0.8485
31-2	0.829 \pm 1.5197
30-3	0.813 \pm 1.531
29-4	0.799 \pm 1.542

Мотивација за коришћење Наивног Бајесовог класификатора је првенствено једноставност његове имплементације на чипу у поређењу са осталим класификаторима (фази логика, метода потпорних вектора, стабла одлучивања, неуронске мреже итд.). ФПГА се користи због паралелног израчунавања сваке од независних вероватноћа, а план је да се имплементира у обради података у реалном времену на лицу места. Имплементација других, сложенијих класификатора би захтевала сложенију логику, коју је тешко синтетизовати на хардверу (Lin and Lee 2011, Nedjah, da Silva and de Macedo Mourelle 2012). Поред тога, због природе проблема са хернијацијом диска, брза обука и процедура тестирања је загарантована као и ефикаснији прорачун у поређењу са другим методама класификације.

До сада мали је број студија које се баве имплементацијом система са Бајесовом теоремом на ФПГА чипу, а у вези са медицинском дијагностиком. У раду (Šušteršič, Ranković, et al. 2020) истраживана је примена Бајесове теореме на мерење силе стопала са могућношћу локализације нивоа дискус херније, али само коришћењем софтверских решења, док је у референци (Šušteršič, Milovanović, et al. 2020) извршено поређење класификатора као система за подршку одлучивању у дијагностици дискус херније.

Главна предност система имплементираниог на ФПГА чипу је чињеница да се коришћењем ФПГА може реализовати систем за аквизицију, обраду и подршку одлучивању у реалном времену сигнала у дијагностици дискус херније и пост-хируршком опоравку. У том смислу, ФПГА има предност у односу на GPU када је у питању аквизиција и анализа сигнала на лицу места. Ово истичу и (Chowdhury and Saha 2010), који имплементирају систем за предвиђање патофизиолошког стања пацијента, са циљем да упозори пацијенте који живе у руралним областима да се јаве лекарима ради неопходне неге. Они такође наглашавају да ФПГА решења дозвољавају могућност да се направе јефтина подешавања дијагностичких алгоритама који се мапирају на хардвер (Chowdhury, Chakrabarti and Saha 2008). Главна мотивација у овој дисертацији да се користи ФПГА је тестирање алгоритама на чипу који је већ комерцијалан. Након одабира коначног алгорита, логика се може користити за дизајнирање универзалног чипа који ће бити способан да имплементира Бајесов или било који други алгоритам вештачке интелигенције за биомедицинску обраду сигнала. Стога ФПГА служи као међукорак у постизању овог циља.

Главни доприноси предложене методе у овој дисертацији су:

- Имплементација Бајесове теореме за потребе објективне дијагностике дискус херније на ФПГА.
- Систем је у стању да разликује здраве субјекте и субјекте са дискус хернијом, тако да може да открије и побољшање стабилности након операције или физикалне терапије.
- Систем је у стању да се повеже са преносивом платформом за мерење силе стопала, чиме се постиже потреба за јефтином преносивом платформом на лицу места за објективну дијагностику, независно од било ког рачунара/лаптоп-а.
- Приказане симулације задовољавају ограничења анализе у реалном времену, тако да будући преносиви уређај прилагођен кориснику може да смањи време прегледа и ред за дијагностику пацијената.

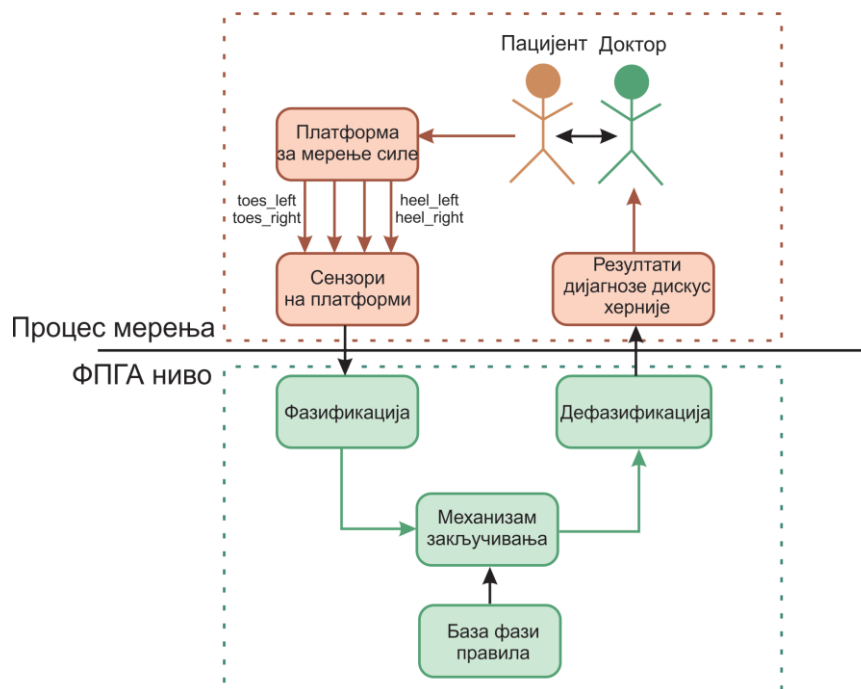
Ограничење које се може јавити је да, уколико платформа за мерење није увек повезана са ФПГА плочом, значи да се анализа не обавља у реалном времену, већ се уместо тога ослања на читање из *.txt* датотеке и даља анализа се врши на чипу. Међутим, показано је да се може симулирати коришћење Бајесове теореме на ФПГА чипу, што представља допринос ове дисертације. Тежња је била да се покаже да је имплементација оваквог алгоритама на чипу могућа, а у будућности ће он бити део преносиве платформе за дијагностику дискус херније на лицу места, која ће моћи да врши аквизицију и анализу у реалном времену.

6.2. Имплементација фази логике на ФПГА чипу

Комплексне процесе које обично надзоришу експерти треба описати коришћењем модела несигурности (Bhole, Agashe and Deshpande 2013). Иако се адекватан ниво прецизности може постићи квантификацијом несигурности, за већину процеса, боље решење је прихватање одређеног нивоа непрецизности коришћењем фази логике (енгл. *fuzzy logic*). Ова логика описује непрецизност и неизвесност коришћењем експертске базе знања као основе у контроли сложеног система управљања процесом (Bhole, Agashe and Deshpande 2013). Фази систем закључивања (енгл. *Fuzzy inference system (FIS)*), ако је организован у облику операција сабирања и одузимања, уколико се имплементира на ФПГА, омогућио би знатно боље искоришћење ресурса, као и убрзање обављања процеса. Имплементација операције дељења помоћу ФПГА је изазован задатак и доводи до губитка неких предности коришћења хардвера, пошто операција дељења заузима много ФПГА ресурса. Стога су Bhole, Agashe and Deshpande (2013) предложили нови алгоритам који користи конверзију фиксног у покретни зарез, а користили су га у имплементацији операције дељења са покретним зарезом у фази логици. Њихов главни закључак је био да предложена методологија за конверзију фиксног у покретни зарез смањује временска ограничења и побољшава коришћење ресурса.

6.2.1. ФПГА имплементација фази логике за дијагностику дискус херније

Као што је већ поменуто, главни изазови у имплементацији фази логике су димензионалност, одзив у реалном времену и тачност. Ови изазови се могу решити коришћењем реконфигурабилне архитектуре, паралелне обраде и операција у формату са покретним зарезом које су доступне преко ФПГА. Слика 6.5 приказује предложени блок дијаграм за ФПГА имплементацију обраде сигнала за дијагностику дискус херније коришћењем фази логике, заједно са системом за мерење силе стопала (Šušteršič, Peulić and Peulić, 2021).



Слика 6.5 Блок дијаграм предложеног спрегнутог ФПГА система за обраду сигнала и платформе за мерење силе стопала

Пацијент се најпре подвргава мерењу: хардвер за мерење укључује две већ описане идентичне платформе са одређеном површином на коју се постављају стопала пацијента. Као што је већ објашњено у поглављу методологије, мерна подручја имају четири сензора по стопалу постављена на одређеним тачкама сваког стопала: Л1-3 сензори за лево стопало постављени на предњи део стопала, Л4 сензор постављен на пету левог стопала, Д1-3 сензори за десно стопало постављени на предњи део стопала, Д4 сензор постављен на пету десног стопала. Процедура мерења обухватала је три сегмента, као што је већ напоменуто, који се изводе један за другим у једном непрекидном снимању:

1. пацијент нормално стоји на обе ноге,
2. пацијент стоји на обе ноге, али само предњим делом стопала/прстима (за стајање на метатарзалним главама овде се користи термин предњи/прсти),
3. пацијент стоји само на петама.

На основу ових мерења, просечне вредности, које се користе као атрибути се израчунавају директно на микропроцесору (Слика 6.5):

1. просечна мерна вредност са Л1-Л3 сензора током стајања на прстима левог стопала (даље означено као *toes_left*),
2. просечна вредност мерења са сензора Д1-Д3 током стајања на прстима десног стопала (даље означено као *toes_right*)
3. просечна вредност мерења са Л4 сензора током стајања на левој пети (даље означена као *heel_left*),
4. просечна вредност мерења са Р4 сензора током стајања на десној пети (даље означена као *heel_right*).

Ове вредности се затим шаљу у ФПГА ради фазификације. Процес се састоји од уобичајених корака у фази систему – фазификација, механизам закључивања који укључује базу знања и дефазификацију. Дефазификована вредност се враћа као информација лекару у виду индикатора да ли је дискус хернија уопште дијагностикована и ако јесте, на ком нивоу је откривена:


1. дискус хернија на левој страни на нивоу диска Л4/Л5,
2. дискус хернија на десној страни на нивоу диска Л4/Л5,
3. дискус хернија на левој страни на нивоу диска Л5/С1 и
4. дискус хернија на десној страни на нивоу диска Л5/С1.

6.2.2. Фази теорија – кораци у дизајну система закључивања

Генерално, фази систем закључивања представља нелинеарно мапирање улазних карактеристика у дискретну вредност излаза засновану на неколико корака. Предност фази логике представља број могућности које се могу постићи различитим пресликавањима (Bhole, Agashe and Deshpande 2013). Даље ће бити укратко представљен ФИС (енгл. *fuzzy inference system(FIS)*) систем и биће описано како се користи при аутоматској дијагностици дискус херније. Сваки ФИС треба да садржи следеће кораке:

1. Дефиниција циљева: ФИС систем би требало да буде у стању да одреди ниво дискус херније, на основу мерења силе стопала добијених коришћењем хардвера који је детаљно описан у раду (Peulić, Šušteršič and Peulić 2018).

2. Одређивање лингвистичких променљивих и фази правила: Фази логика подразумева резоновање коришћењем фази скупова и опис лингвистичких променљивих, док се најчешће користе троугласте или трапезоидне функције припадности. Диск хернија је нелинеаран процес, који се може мапирати коришћењем трапезних функција припадности као што је приказано у референци (Peulić, Šušteršič and Peulić 2018). Како тачност дефиниције директно зависи од фази скупова, логично је да ако се број фази скупова повећа, резолуција и тачност расте. Међутим, и сложеност ФИС-а се повећава. Да би се успоставила равнотежа између сложености и тачности, за сваки улаз (лингвистичу променљиву) се бирају три фази скупа – веома низак, низак и нормалан (Слика 6.6).



Слика 6.6 Лингвистичке варијабли које се користе у процесу фазификације за дијагностику дискус херније


3. Формулисање базе знања: Одлука се доноси на основу стручног знања које дефинише лекар. Дефинисана су 42 фази правила имплементирана као LUT која описују процес дијагностиковања нивоа дискус херније. Примери неких правила су:
- Ако је *toes_left* ВРЛО_НИЗАК и *toes_right* је НОРМАЛАН и *heel_left* је НОРМАЛАН и *heel_right* је НОРМАЛАН, тада ће дијагноза бити Л5/С1 НА ЛЕВОЈ СТРАНИ,
 - Ако је *toes_left* НОРМАЛАН, а *toes_right* ВРЛО_НИЗАК и *heel_left* је НОРМАЛАН и *heel_right* је НОРМАЛАН, тада ће дијагноза бити Л5/С1 НА ДЕСНОЈ СТРАНИ,
 - Ако је *toes_left* НОРМАЛАН, а *toes_right* је НОРМАЛАН и *heel_left* је НИСКО и *heel_right* је НОРМАЛАН, тада ће дијагноза бити Л4/Л5 НА ЛЕВОЈ СТРАНИ,
 - Ако је *toes_left* НОРМАЛАН, а *toes_right* је НОРМАЛАН и *heel_left* је НОРМАЛАН и *heel_right* је НИЗАК, тада ће дијагноза бити Л4/Л5 НА ДЕСНОЈ СТРАНИ.
4. Одређивање оператора конјункције и дисјункције: оператори конјункције и дисјункције се дефинишу у консултацији са лекаром-експертом. За операторе је коришћен $\text{MAX}(x_1, x_2, x_3, x_4)$.

5. Дефазификација: Да би се одредио дискретан резултат и коначна одлука из ФИС-а, може се применити неколико метода. У Мамдани ФИС-у, најчешће коришћена метода је метода тежишта. Међутим, Мамдани метода није погодна за овај проблем, јер захтева проналажење тежишта дводимензионалног облика интеграцијом преко континуирано променљиве функције (Kusiak 2004). Ова метода није рачунски ефикасна нити је излаз у облику троугла или трапезоидних функција припадности лак за имплементацију. Штавише, прорачун дефазификације је веома компликован за постизање у VHDL-у. (Sagaria 2008) је доказао да са Мамданијевим методом резултати нису нужно ефикасни или бољи и да је Сугено стил много погоднији за хардверску имплементацију. Ово је последица чињенице да излаз ове методе користи дискретне вредности зване *singleton*, што значи да има вредност јединице у једној одређеној тачки и да је нула на другим местима. Ово доводи до тога да је излаз сваког фази правила константа. Због тога, предност Сугено методе је због своје једноставности, што омогућава спровођење брзих прорачуна и релативно је лако имплементирати је на хардверу. Према референци (Deliparaschos and Tzafestas 2006), фази процесор заснован на методи Сугено представља добар компромис између хардверске једноставности и ефикасности, а без губитка у тачности. Као закључак, овде је представљена Сугено метода, која боље одговара потребама хардверске имплементације, за разлику од Мамданијеве методе у софтверској имплементацији представљене у (Peulić, Šušteršič and Peulić 2018).
6. Тестирање и валидација: Тестирање система и подешавање правила је постигнуто кроз неколико итерација, све док се не добију задовољавајући резултати. Већ је доказано да се предложени систем фази закључивања може користити за дијагностику дискус херније (Peulić, Šušteršič and Peulić 2018).

6.2.3. Анализа сигнала применом фази логике на ФПГА чипу

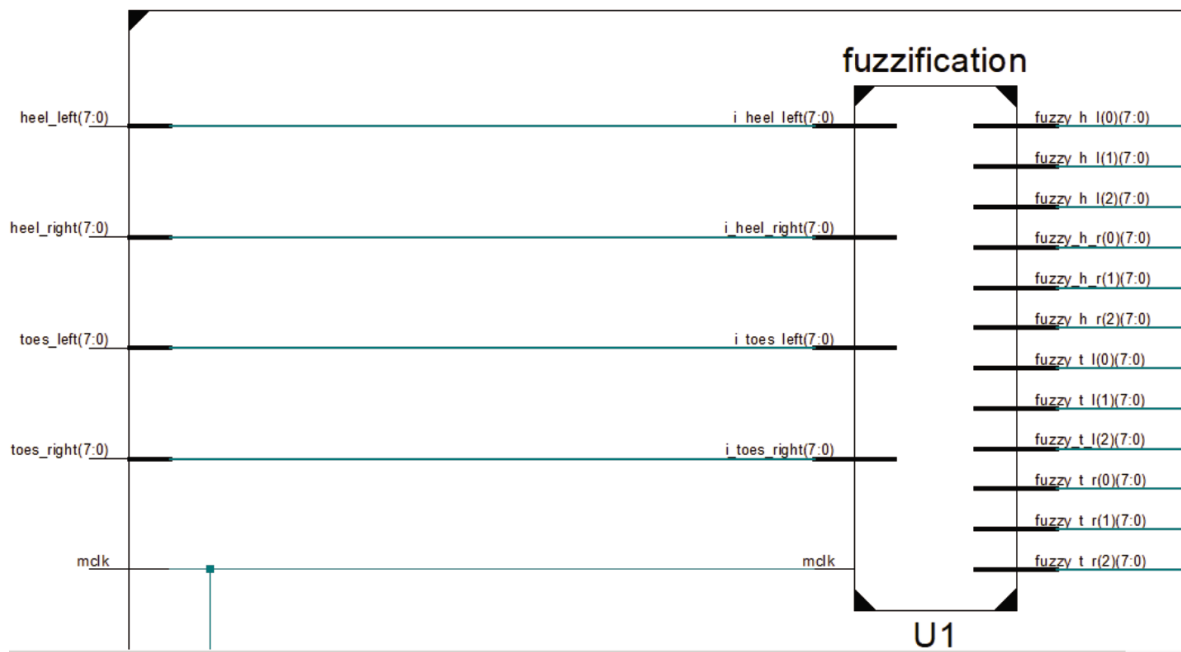
Логички дизајн у реалном времену (енгл. *real time logic (RTL)*) целокупног креираног система је развијен и биће детаљно објашњен (Слика 6.7) (Šušteršič, Peulić and Peulić, 2021). Улаз у систем фази закључивања представљају четири вредности мерења силе стопала, као што је претходно поменуто: просечна вредност мерења са сензора Л1-Л3 током стајања на левом предњем делу стопала (даље означено као *toes_left*), просечна вредност мерења са сензора Д1-Д3 током стајања на десном предњем делу стопала (даље означена као *toes_right*), просечна вредност мерења са сензора Л4 током стајања на левој пети (даље означена као *heel_left*), и просечна вредност мерења са Д4 сензора током стајања на десној пети (даље означена као *heel_right*). Сви резултати су представљени као 8-битни *std_logic_vector(7:0)*. Наравно, улази у *top_module* представљају *clear (clr)* и главни такт (*mclk*) од 50MHz. Разлог за коришћење 50MHz је тај што је главни такт на Nexys 2 плочи (једина доступна плоча у нашем случају која се користи за имплементацију у реалном времену) дате фреквенције, али се фреквенција *mclk*-а може лако променити у зависности од доступне плоче. Излаз система представља дијагнозу у виду 4-битног вектора (*led(3:0)*), где четири 0000 представљају здраву особу, а свака 1 у четворобитном вектору представља једну од дијагноза (1000 – Л4/Л5 на левој страни, 0100 – Л4/Л5 на десној страни, 0010 – Л5/С1 на левој страни, 0001 –

Л5/С1 на десној страни). Други излаз система је *maximum(7:0)*, који представља сигурносну вероватноћу израчунате дијагнозе.



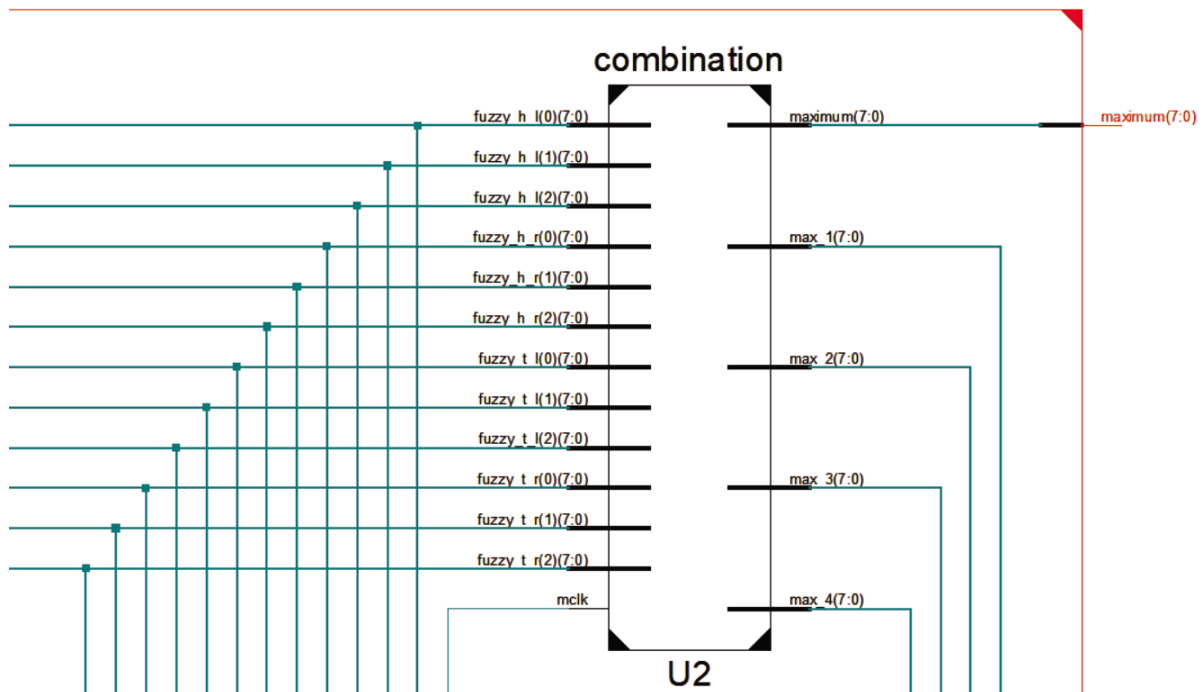
Слика 6.7 RTL шема *top_module* за систем дијагнозе расплинуте диск херније

Унутар *top_module*, први подсистем је У1 који представља подсистем фазификације (Слика 6.8). Систем узима четири улазне вредности и фазификује их према дефинисане три језичке варијабле - веома ниска, ниска и нормална, што указује на слабост мишића. Након тога, на основу LUT табеле, за сваки улаз, креира се низ од три вредности које указују на степен припадности свакој језичкој променљивој. Ово се ради на начин да се избегне формат са покретним зарезом, тако да се степен припадања скалира да буде у опсегу од 0-100 (уместо 0 - 1). Степен припадања се израчунава унапред на основу једначине за линеарну функцију кроз две тачке и имплементира као LUT табела. У LUT табели, вредност са степеном припадности је израчуната за тачке на x осе са дискретизацијом од 0.2. Вредности се тада множе са 10, исто као и за вредност x осе, да би се избегао формат са покретним зарезом и рад са целобројним вредностима. Иста логика је примењена у (Oliveira, de Souza Braga and da Mota Almeida 2010) и (Chowdhury, Chakrabarti and Saha 2008). То значи да је вредност μ израчуната унапред за 0 (0), 0.2 (20), 0.4 (40) итд. и прослеђена LUT-у. Улазне вредности морају бити заокружене на паран број и све су у опсегу од 0 - 21 (210), који је покривен 8-битним вектором. Систем је тестиран и са фином и са грубљом дискретизацијом и показало се да усвојена дискретизација има најбољи однос између сложености и тачности. На пример, за улаз *toes_left(7:0)*, креира се низ *fuzzy_t_l*, где *fuzzy_t_l(0)(7:0)* указује на веома низак степен припадности језичкој променљивој, *fuzzy_t_l(1)(7:0)* означава низак степен припадности језичкој променљивој и *fuzzy_t_l(2)(7:0)* указује на нормалан степен припадности језичкој променљивој. Исте излазне вредности се даље преносе и на У2 и У3.



Слика 6.8 RTL шема U1 подсистема за фазификацију улазних података


Ове променљиве $fuzzy_t_l$, $fuzzy_t_r$, $fuzzy_h_l$, $fuzzy_h_r$ се прослеђују систему U2 (Слика 6.9) које комбинују максималне вредности за поменуте променљиве и одређују укупни максимални степен припадности и максимум за три фази скупа по улазу. Излаз система је максимална вредност обојена црвеном бојом (максимална вредност функције припадања).



Слика 6.9 RTL шема U2 подсистема за комбинацију улазних фазификованих података

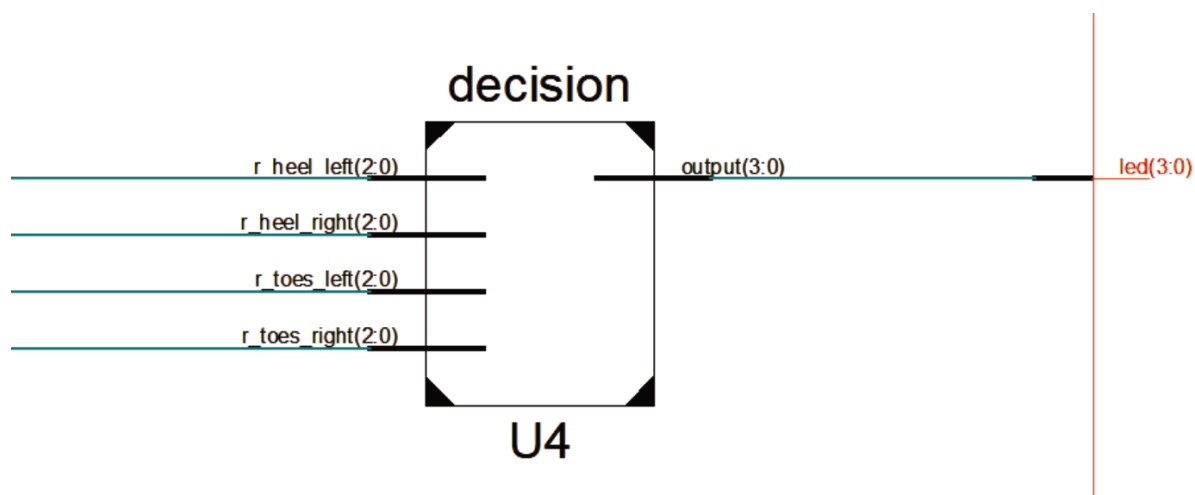
Исте ове променљиве $fuzzy_t_l$, $fuzzy_t_r$, $fuzzy_h_l$, $fuzzy_h_r$ се прослеђују систему U3 (Слика 6.10), заједно са израчунатим вредностима максимума од $max_1(7:0)$ до $max_4(7:0)$ да би се утврдило који су фази скупови активни. Све ово је

организовано на такав начин да се $max_1(7:0)$ до $max_4(7:0)$ пореди са $fuzzy_t_l(7:0)$, $fuzzy_t_r(7:0)$, $fuzzy_h_l(7:0)$, $fuzzy_h_r(7:0)$, а 001 се помера улево неколико пута, што одговара индексу $fuzzy_x_x$ који пак одговара вредности max_x . То значи да ће само једна лингвистичка променљива бити активна по фазификованом улазном биту који је једнак 1, на месту које одговара активираној лингвистичкој променљивој. Затим се креирају четири излаза $r_toes_left(2:0)$, $r_toes_right(2:0)$, $r_heel_left(2:0)$, $r_heel_right(2:0)$, при чему ће само један бит имати вредност 1, а преостала два бита ће бити 0.



Слика 6.10 RTL шема U3 подсистема за кодирање улазних података

Израчунате променљиве $r_toes_left(2:0)$, $r_toes_right(2:0)$, $r_heel_left(2:0)$, $r_heel_right(2:0)$ служе као улаз за коначни блок U4 приказан на слици (Слика 6.11). Овај блок је одговоран за активацију правила. Укупно су написана 42 правила на основу експертског знања. Коначни излаз је четворобитни излаз $output(3:0)$, где позиција бита са вредношћу 1 указује на одговарајућу дијагнозу (1000 – Л4/Л5 на левој страни, 0100 – Л4/Л5 на десној страни, 0010 – Л5 /С1 на левој страни, 0001 – Л5/С1 на десној страни). Дијагноза излаза може бити приказана као ЛЕД лампица на ФПГА хардверској плочи, где позиција лед лампе означава одговарајућу дијагнозу, тако да није потребно познавање хардвера да би се разумео коначни излаз на плочи.



Слика 6.11 RTL шема U4 подсистема за коначну одлуку (дефазификација)

6.2.4. Коришћени сет података

Скуп података коришћен у овој дисертацији укључивао је мерења силе ослањања 58 одрасла испитаника (дијагностификованих са Л4/Л5 или Л5/С1 дискус хернијом или здраве испитанике) и 33 одрасла испитаника након операције и физикалне терапије. Њихово здравствено стање је процењено пре операције, после операције и после физикалне терапије, коришћењем пројектованог система и на основу лекарског мишљења. Подаци за преоперативне испитанике су дати у поглављу Методологија, тако да су овде само допуњени подаци за постоперативне испитанике и испитанике након физикалне терапије. Табела 6.4 даје демографске податке у облику средње вредности \pm стандардна девијација.

Табела 6.4 Демографски подаци тестираних пацијената - постоперативни и после физикалне терапије

Пост оперативно и након физикалне терапије	Број	Старост (године)	Тежина (kg)	Висина (cm)
Мушкарци	17	42 \pm 13.37	90 \pm 13.30	182 \pm 5.66
Жене	16	42 \pm 13	66 \pm 9	169 \pm 7

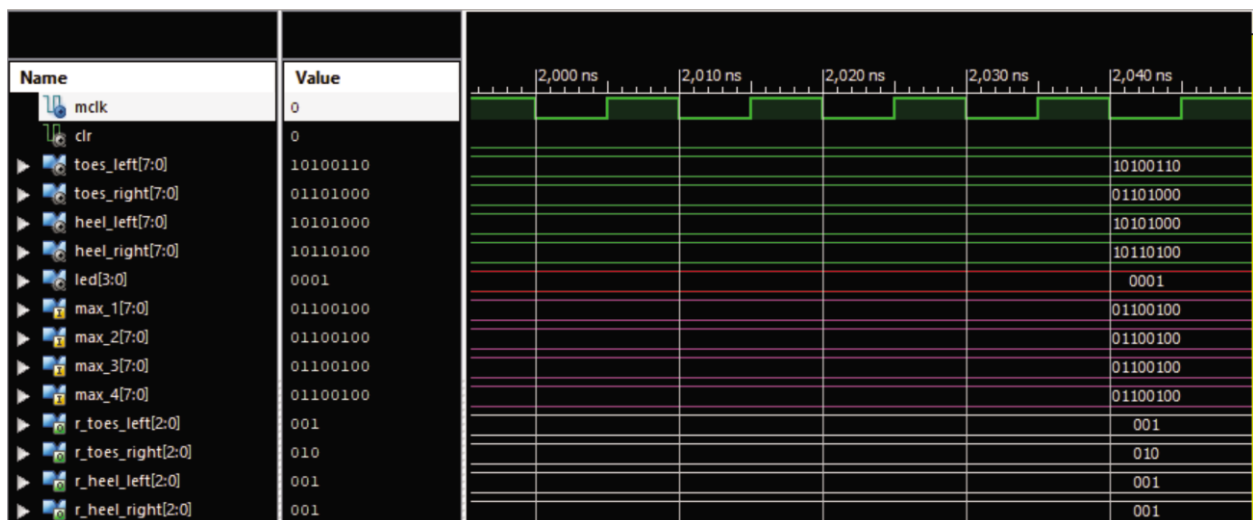
Дистрибуција пацијената са дискус хернијом после операције и после физикалне терапије, разврстано у четири различите категорије је била:

1. диск хернија на левој страни на нивоу диска Л4/Л5 (9 пацијената),
2. диск хернија на десној страни на нивоу диска Л4/Л5 (5 пацијената),
3. диск хернија на левој страни на нивоу диска Л5/С1 (7 пацијената),
4. диск хернија на десној страни на нивоу диска Л5/С1 (12 пацијената).

6.2.5. Резултати имплементације фази логике на ФПГА чипу

Резултати су показали да је пројектовани систем довољно тачан да се може користити као преносиви систем са мерним платформама. Такође, систем је у стању да открије побољшање (већу мишићну снагу) након операције и физикалне терапије (Šušteršič, Peulić and Peulić, 2021). Као што је раније речено, резултати показују да је мања вредност силе на предњем делу стопала забележена на одговарајућем стопалу код пацијената са дијагнозом Л5/С1 диск херније, док је слабија вредност силе на пети забележена на одговарајућем стопалу код пацијената са дијагнозом диск херније Л4/Л5. На пример, код пацијената са дијагнозом диск херније Л4/Л5 на левој страни, детектована је мања сила на пети на левом стопалу; ако је пацијенту дијагностикована диск хернија Л5/С1 на десној страни, уочена је мања сила предњег дела десног стопала итд. Резултати се поклапају са претходно објављеним резултатима у референци (Peulić, Šušteršič и Peulić 2018) и са дијагностиком коју је поставио лекар. Медицинска дијагностика примењивана у пракси се поклапа са резултатима и закључцима добијеним у овој докторској дисертацији. Медицинско тумачење налази се у чињеници да инервација мишића и подручја коже који су присутни на ножним прстима потиче од нерава између Л5 и С1 дискова у кичми, док се инервација пета врши преко нерава који настају између Л4 и Л5 дискова у кичми (Winn 2011, Greenberg and Arredondo 2001).

Слика 6.12 даје пример дијагностиковане Л5/С1 дискус херније на десној страни. Најважнији сигнали су већ објашњени у одељку 6.2.3. - Анализа сигнала применом фази логике на ФПГА чипу. Улази у систем су четири снимљене вредности $toes_left(7:0)$, $toes_right(7:0)$, $heel_left(7:0)$, $heel_right(7:0)$. Додатне променљиве $r_toes_left(2:0)$, $r_toes_right(2:0)$, $r_heel_left(2:0)$, $r_heel_right(2:0)$ показују функције припадности које активира свака улазна променљива након фазификације. Променљиве $max_1(7:0)$, $max_2(7:0)$, $max_3(7:0)$, $max_4(7:0)$ дефинишу степене припадности претходно објашњених активираних фази скупова. Излаз је $led(3:0)$ где позиција 1 означава дијагнозу, а у овом случају број 1 на последњој позицији означава откривену дијагнозу Л5/С1 на десној страни.



Слика 6.12 Резултати симулације у случају Л5/С1 дискус херније са десне стране

Резултати за преоперативно стање показују да је од 58 испитаника, код 54 пацијента постављена тачна дијагноза коришћењем кода у Матлаб-у која одговара

златном стандарду (Табела 6.5). Од три погрешно класификоване дијагнозе, једна је била Л4/Л5 на левој страни, две Л5/С1 на десној страни и једна код здравог испитаника, што значи да је укупна тачност била 93.1%.

Табела 6.5. Поређење резултата за преоперациону дијагнозу на основу златног стандарда, резултата добијених коришћењем Матлаб-а и имплементацијом на ФПГА

Преоперациона дијагноза	Златни стандард (лекар)	Број тачно дијагностикованих пацијената	
		Матлаб	ФПГА
Л4/ Л5 са леве стране	9	8	7
Л4/ Л5 са десне стране	5	5	5
Л5/С1 са леве стране	7	7	7
Л5/С1 са десне стране	12	10	8
Здрави испитаници	25	24	24

За поменути четири испитаника са погрешном дијагнозом у односу на златни стандард, два пацијента су класификована као здрава, што значи да систем није могао да детектује дискус хернију ни на једном нивоу, због малих разлика у забележеним силама, које нису биле довољне да се дијагностификује дискус хернија. Два испитаника су дијагностикована са Л4/Л5 на десној страни (уместо Л5/С1 на десној страни и здрав испитаник), јер је забележена вредност силе на десној пети била близу нуле. Разумљиво је зашто је систем дао такво решење као излаз, како у Матлабу, тако и на ФПГА, пошто је могло да се деси да сензори нису били добро подешени да одговарају величини стопала пацијента, па самим тим ни сила није била добро забележена.

Поред тога, извршено је поређење резултата фази система имплементираних у Матлабу, који користи формат с покретним зарезом са резултатима добијеним са имплементираним логиком на ФПГА (Табела 6.5, друга и трећа колона). Три пацијента су показала неслагање између резултата које је дао Матлаб и ФПГА излаз. Разлог за то је начин на који је извршена дискретизација која није била довољно детаљна. Међутим, ако се усвоји детаљнија дискретизација, ови случајеви су могли бити укључени. Због тога, пацијенти су погрешно класификовани од стране ФПГА, у поређењу са Матлаб излазом (једна дијагноза је била Л4/Л5 на левој страни, а две су биле дијагнозе Л5/С1 на десној страни). То значи да су тачности за сваку дијагнозу, коришћењем ФПГА у поређењу са Матлаб-ом, биле:

- Л4/ Л5 са леве стране – 0.875,
- Л4/ Л5 са десне стране – 1.00,
- Л5/С1 са леве стране – 1.00,
- Л5/С1 са десне стране – 0.80,
- Здрави испитаници – 1.00.

Добри резултати који су добијени при поређењу преоперативне дијагнозе између ФПГА и Матлаба потврђени су и за резултате после операције и после физикалне терапије. У случају пост-оперативног стања, Матлаб и ФПГА резултати

су се поклапали 100%, при чему је побољшање детектовано у 18 случајева (54.5% пацијената) (Табела 6.6).

Табела 6.6 Поређење резултата са побољшаним стањем након операције на основу златног стандарда, резултата добијених коришћењем Матлаб-а и ФПГА

Преоперациона дијагноза	Број пацијената са побољшаним стањем		
	Златни стандард (лекар)	Матлаб	ФПГА
Л4/ Л5 са леве стране	4	4	4
Л4/ Л5 са десне стране	3	3	3
Л5/С1 са леве стране	4	4	4
Л5/С1 са десне стране	7	7	7

Од тога, побољшање је показало 4 од 9 пацијената са Л4/Л5 на левој страни, 3 од 5 пацијената са Л4/Л5 на десној страни, 4 од 7 пацијената са Л5/С1 на левој страни и 7 од 12 пацијената са Л5/С1 на десној страни. Дијагноза лекара је потврдила сва ова побољшања, што значи да је златни стандард одговарао резултатима добијеним коришћењем Матлаб/ФПГА. Једном пацијенту је након операције погрешно дијагностикована Л5/С1 диск хернија на левој страни, док је пре операције дијагноза била Л5/С1 диск хернија на десној страни. До проблема је дошло при доношењу одлуке у вези са два пацијента, који су имали веома ниске вредности на неким од сензора – један пацијент је био исти пацијент, као што је горе описано, са силом на десној пети која је била близу нуле. Пошто је иста ситуација поново уочена након физикалне терапије, може се закључити да овај пацијент (женског пола) вероватно имао веома мала стопала која нису била добро позиционирана на платформи и самим тим сензори нису били добро подешени тако да одговарају стопалима овог пацијента. Како је база података била сачињена само од 33 пацијента, овај пацијент није искључен из скупа података, али се зато скреће пажња лекарима да морају да обрате пажњу приликом постављања и подешавања сензора.

За стање после физикалне терапије, још већи број пацијената је показао побољшање мишићне снаге (23 пацијента) - 7 од 9 пацијената са Л4/Л5 на левој страни, 5 од 5 пацијената са Л4/Л5 на десној страни, 5 од 7 пацијената са Л5/С1 на левој страни и 6 од 12 пацијената са Л5/С1 на десној страни (Табела 6.7).

Табела 6.7. Поређење резултата за побољшање стања након физикалне терапије на основу златног стандарда, резултата добијених коришћењем Матлаб-а и ФПГА

Преоперациона дијагноза	Број пацијената са побољшаним стањем		
	Златни стандард (лекар)	Матлаб	ФПГА
Л4/ Л5 са леве стране	7	7	7
Л4/ Л5 са десне стране	5	5	5
Л5/С1 са леве стране	5	5	5
Л5/С1 са десне стране	6	6	6

Као што је већ напоменуто, код једног пацијента забележене су вредности близу нуле на више од једног сензора за преоперативно, пост-оперативно мерење и после физикалне терапије, што је довело до лажних резултата због систематске грешке у мерењу. Осталих 5 погрешно дијагностикованих случајева су били један случај Л5/С1 са десне стране, 2 погрешно дијагностикована Л5/С1 на левој страни и 2 погрешно дијагностикована Л4/Л5 на левој страни, а грешке у мерењу су заправо довеле до погрешних закључака. Када је у питању поређење резултата добијених применом Матлаб-а и ФПГА, поклапање је било 100%, што значи да су Матлаб и ФПГА у свим случајевима дали исте излазе, као и да је постигнуто исто подударане у поређењу са златним стандардом.

Време симулације за добијене резултате било је реда величине ns, док Табела 6.8. даје резиме коришћења ресурса уређаја. Доступни коришћени хардвер је била Nexys 2 плоча, која је комплетна развојна платформа заснована на Xilinx Spartan 3E FPGA (Nexys 2008). Поред чипа 500K-gate Spartan 3E-500 FG320 chip, платформа има 50MHz осцилатор плус прикључак за други осцилатор, 16MB Micron PSDRAM & 16MB са Intel Strata Flash ROM екстерном меморијом, и неколико I/O уређаја и портова који омогућавају кориснику да обавља сложене имплементације различитих алгоритама.

Табела 6.8. Резиме коришћења ресурса уређаја

	Искоришћено	Доступно	Процент искоришћености
Број слајсева	522	4656	11%
Број флип флопова	12	9312	0%
Број лукап табела	933	9312	10%
Број улазно-излазних блокова	44	232	18%

Аутори у референци (Deliparaschos and Tzafestas 2006) су у својим истраживањима користили идеју обраде само активних правила (мисли се на правила која дају ненулти допринос коначном резултату), уместо свих правила. Ово се ради како би се смањило коришћење ресурса што се постиже коришћењем LUT-а, а као што се може видети из табеле, чак и са једноставном развојном плочом, резултати су задовољавајући.

Основна идеја је била да се докаже да логика дискретизације која је предложена у овом раду, као и имплементација фази логике као LUT табеле, не доводи до губитка тачности и даје предност коришћењу ФПГА у обради сигнала (на пр. као што је паралелна обрада, убрзавање итд). Главни доприноси предложеног система су:

- имплементација фази логике за потребе објективне дијагностике диск херније на ФПГА,
- фази систем закључивања је реализован у облику табеле за тражење (LUT), како би се задовољила потражња за ефективним коришћењем ресурса,
- систем је у стању да се повеже са преносивом платформом за мерење силе стопала, чиме се постиже потреба за јефтиним преносивом платформом на лицу места за објективну дијагностику, независно од било ког рачунара/лаптоп-а,

- фази систем је адаптиран и користи Сугено метод у поређењу са фази системом који је користио Мамдани метод описан у (Peulić, Šušteršič и Peulić 2018) како би био погоднији за хардверску имплементацију,
- преносиви уређај је једноставан за коришћење са брзом анализом у реалном времену, чиме се смањује време и ред за дијагностику,
- систем је у стању да детектује побољшање мишићне снаге након операције и физикалне терапије у односу на стање пре операције, што до сада није истраживано ни у једном другом раду (Šušteršič, Peulić and Peulić, 2021).

Поред тога, главна предност је што се ФПГА чип може користити за повезивање са мерном платформом, постижући обраду података у реалном времену, без употребе различитих апликација, лаптопова/рачунара итд. Такође, веома лако може да се изведе да се дијагноза исписује на лед дисплеју или слично, што је једноставније за корисника/лекара. Стандардни микроконтролер пружа флексибилност у имплементацији базе знања и избору алгоритама закључивања. Ипак, исти микроконтролери постају неадекватни за примену када се решавају проблеми који захтевају велике брзине закључивања, малу величину и ниску потрошњу енергије. Из тог разлога се морају изабрати специфичнија хардверска решења, као што су ФПГА, која су више него адекватна када је неопходно да се испуне потребе за апликацијама које се односе на преносиве уграђене системе или строге захтеве у реалном времену (Barriga, et al. 2006, Nilosey 2014).

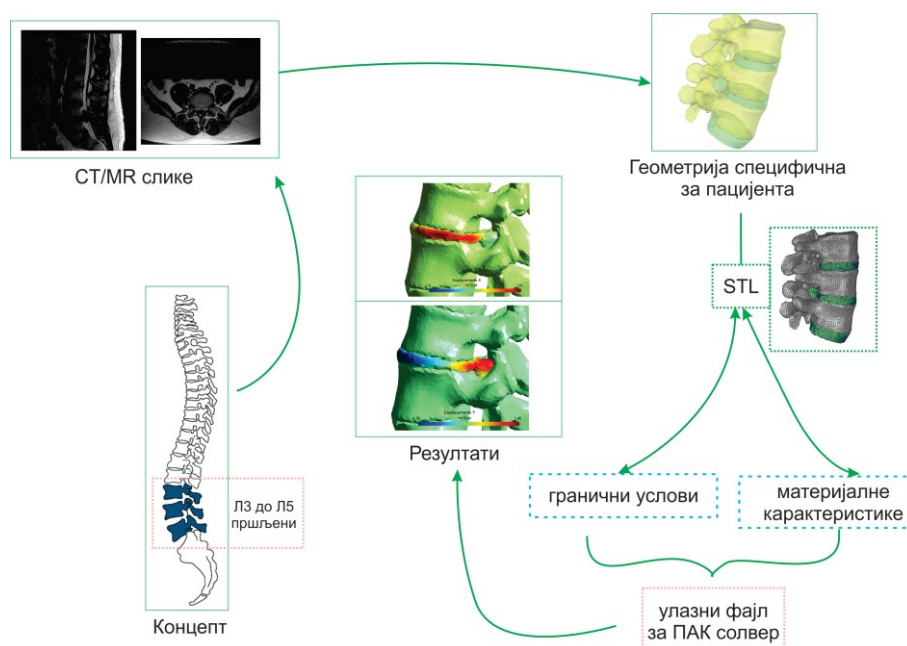
Примена фази логике можда не представља најбољи приступ у решавању ове врсте проблема у поређењу са напреднијим алгоритмима вештачке интелигенције. Међутим, фази логика се веома лако имплементира на ФПГА у поређењу са неуронским мрежама, методом потпорних вектора итд., а добијени резултати показују високу тачност чак и када се користи без примене сложених алгоритама. Теорија која стоји иза откривања дијагнозе дискус херније је заснована на правилима АКО-ОНДА, и стога примена фази логике представља логичан избор у решавању проблема ове врсте. Главна предност система имплементираниог на ФПГА је да се у реалном времену може имплементирати систем за прикупљање и обраду сигнала као и подршку одлучивању у дијагностици дискус херније и пост-хируршком опоравку. У том смислу, ФПГА има значајну предност у односу на графичке картице када је у питању аквизиција и анализа сигнала у реалном времену.

7. НУМЕРИЧКА АНАЛИЗА ОПТЕРЕЂЕЊА ИНТЕРВЕРТЕБРАЛНОГ ДИСКА

Нумеричке симулације које користе методу коначних елемената (енгл. *Finite Element Method (FEM)*) за механичку анализу биомеханике лумбалних дискова пружају додатне информације о понашању диска услед статичког и динамичког оптерећења пацијента. Због тога је веома важно креирати модел специфичан за пацијента који тачно приказује геометрију лумбалног дела кичме. Ово поглавље се ослања на методе вештачке интелигенције приказане у претходним поглављима за потребе аутоматске детекције и сегментације области дискуса на сликама магнетне резонанце. Како је мануелна сегментација региона од интереса временски захтевна, аутоматске методе засноване на вештачкој интелигенцији помажу у скраћењу времена. Након издвајања региона диска и пршљена, врши се тродимензионална реконструкција геометрије, а затим и нумеричке симулације оптерећења интервертебралног диска (Šušteršič, et al. 2022).

Стварање једног комплетног модела подразумевало би укључивање карактеристика специфичних за људско тело, као што су нпр. различите врсте материјала. Међутим, нуклеус интервертебралних дискова није униформан и дегенерација диска се дешава брзо, тако да заправо не постоје експериментално израчунате вредности за одређене материјалне константе, те се обично користе литературне вредности. У FEM анализи, неопходно је разликовати материјал који представља тело пршљена, сунђерасти део, али и завршне плоче (енгл. *endplates*). Baroud, et al. (2003) користили су кортекс од 1 mm и дебљину завршне плоче од 0.5 mm. Дебљина слоја хрскавице фасетног зглоба (Schmidt, Kettler, et al. 2007) усваја се да је 0.2mm. Када је у питању моделирање интервертебралног диска – разликују се нуклеус и анулус. За запремински однос између анулуса и нуклеуса, однос 3:7 се генерално користи за лумбални део L1-C1 (Moramarco, et al. 2010, Goto, et al. 2002). С друге стране, Chen, et al. (2001) су предложили однос од 30-50% између нуклеуса и анулуса у попречном пресеку диска.

Стога је у оквиру ове докторске дисертације предложена методологија за моделирање и нумеричку анализу оптерећења интервертебралног диска. Слика 7.1 даје шематски приказ предложене методологије. За креирање модела коришћене су слике са магнетне резонанце са дебљином слајса 2 mm, код 40-годишњег мушкарца са дискус хернијом на нивоу L4/L5. Други модел је креиран без херније дискуса како би се симулирале ситуације са и без дискус херније. Израчунат је волумен диска изван подручја интервертебралног диска и реконструисан модел без херније (Šušteršič, et al. 2022).



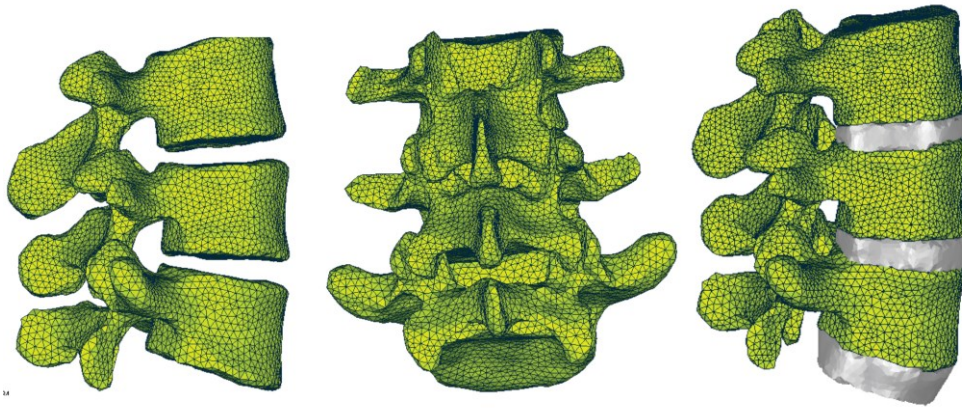
Слика 7.1 Предложена методологија за реконструкцију лумбалног дела кичменог стуба

Скениране слике су биле у DICOM (енгл. *Digital Imaging and Communications in Medicine*) формату, након чега су сваки пршљен у региону (L3–C5) и дискови између одговарајућих пршенова (L3/L4, L4/L5 и L5/C1) екстраховани из слика помоћу објашњених алата за сегментацију, и одговарајуће 3Д геометрије су прецизно реконструисане (Šušteršič, et al. 2022). Због чињенице да су снимци направљени само на репрезентативним пресецима, није било могуће направити разлику између сунђерасте и трабекуларне кости у пршљеновима, као ни између нуклеуса и анулуса. Дакле, овај модел садржи само један материјал за кост и један материјал за структуру диска. Гранични услови су постављени тако да је померање било могуће само у правцу z (вертикални смер), док се материјал диска могао померати у било ком смеру. Додатно, на дну L5/C1 диска је постављена потпора, како се не би дозволило да се цео модел транслира као резултат компресије. Елементи кости и диска пршљенова су моделовани као 3Д чврсти континуални изопараметријски хексаедарски (цигле) елементи са 8 чворова. Табела 7.1 приказује број чворова и елемената за креирани модел здраве особе и особе са дискус хернијом.

Табела 7.1 Број чворова и елемената за креиране моделе


	Пршљенови	Интервертебрални диск	Укупно	
	Број елемената	Број елемената	Број чворова	Број елемената
Модел са здравим диском	369356	127840	575178	497196
Модел са дискус хернијом	369192	126032	573114	495224

Креирани модели здраве особе (без дискус херније) (Слика 7.2) и особе са дискус хернијом (Слика 7.3), укључивали су L3, L4 и L5 пршљенове, као и интервертебралне дискове. Модел здраве особе је за сваки пршљен имао око 6500-7500 површинских елемената. Када је у питању материјал диска, за здраву особу сваки диск је садржао око 2500-3000 површинских елемената.



Слика 7.2 Површинска мрежа модела Л3-Л5 пришљена са интeвертебралним дисковима код особе без дискус херније

Када је реч о особи са дискус хернијом, Л4/Л5 диск је садржао око 2800 површинских елемената (Слика 7.3). На сликама је видљиво да модел здравог диска Л4/Л5 не садржи никакав материјал изван интервертебралног простора, док модел са дискус хернијом садржи запремину изван интервертебралног простора. Дакле, главна разлика лежи у подручју диска где је висина херније диска смањена, и 1.5 mm мања од нормалне висине диска а садржи и екструдирани материјал. Све ово је израчунато на основу запремине диска изван простора интервертебралног диска како би се симулирала ситуација пре хернијације.



Слика 7.3 Површинска мрежа модела Л3-Л5 пришљена са интeвертебралним дисковима код особе са дискус хернијом

Промене у геометрији и својствима материјала су главне карактеристике које се користе за симулацију дегенерације. Исту методологију су користили и други аутори у моделирању дегенерације лумбалних дискова (Kurutz and Oroszváry, 2012). Они у свом истраживању примењују методологију да се задњи анулус ослаби кидањем влакана унутрашњег анулуса и омогући хернијација нуклеарног материјала у спољашњу прстенасту структуру.

Прорачун је извршен коришћењем солвера ПАК за МКЕ анализу, развијеног на Факултету инжењерских наука Универзитета у Крагујевцу, Србија и у Истраживачко развојном центру за биоинжењеринг (БиоИРЦ) (Kojic, et al. 2001).

Својства материјала и прописана оптерећења биће детаљно описани у наредним одељцима.

7.1. Материјални модели кичмених пршљенова и дискова

Како би се остварила висока вредност чврстоће кортикалне кости пршљенова, обично се претпоставља да је материјал линеарно еластични изотропни или попречно изотропни ортотропни (Табела 7.2). Сунђераста кост пршљенова се обично моделује линеарно еластичним изотропним или попречно изотропним или чак ортотропним материјалом (Табела 7.3).

Табела 7.2 Преглед материјалних карактеристика коришћених у моделима кортикалне кости лумбалног пршљена

Материјални модел	E [MPa]	ν	Референца
линеарно еластичан, изотропан	5 000	0.3	(Rohlmann, Bauer, et al. 2006, Zander, et al. 2006)
линеарно еластичан, изотропан	10 000	0.3	(Rohlmann, Zander and Bergmann, 2006, Rohlmann, Zander and Schmidt, et al. 2006, Rohlmann, Burra, et al. 2007, Zhang and Zhu 2019)
линеарно еластичан, изотропан	11 300	0.2	(Little, Percy and Adam 2008)
линеарно еластичан, изотропан	12 000	0.3	(Goto, et al. 2002, Xie, et al. 2017, Hassan, et al. 2020, Zhang, et al. 2009, Kurutz and Oroszváry, 2010)
линеарно еластичан, попречно изотропан	11 300	0.48	(Schmidt, Heuer and Wilke, 2009)
	11 300	0.20	
	22 000	0.20	
линеарно еластичан, попречно изотропан	8 000	0.40	(Malandrino, Planell and Lacroix 2009)
	8 000	0.23	
	12 000	0.35	
пороеластичан	10 000	0.3	(Ferguson and Steffen 2003)

Табела 7.3 Преглед материјалних карактеристика коришћених у моделима сунђерасте кости лумбалног пршљена

Материјални модел	E [MPa]	ν	Референца
линеарно еластичан, изотропан	10	0.2	(Zhong, et al. 2006, Ruberté, Natarajan and Andersson 2009)
линеарно еластичан, изотропан	50	0.2	(Rohlmann, Zander and Bergmann, 2006)
	81	0.2	(Baroud, et al. 2003)
	140	0.2	(Little, Percy and Adam 2008)
	100	0.29	(Zhang, et al. 2009)
	100	0.2	(Hassan, et al. 2020, Goto, et al. 2002)

	150	0.3	(Kurutz and Oroszváry, 2010)
	500	0.2	(Rohlmann, Bauer, et al. 2006, Zander, et al. 2006)
<i>пороеластичан</i>	100	0.2	(Williams, Natarajan and Andersson 2007)
<i>линеарно еластичан, попречно изотропан</i>	200 140	0.45 0.315	(Rohlmann, Burra, et al. 2007, Rohlmann, Zander and Schmidt, et al. 2006)
<i>линеарно еластичан, попречно изотропан</i>	140	0.45	(Malandrino, Planell and Lacroix 2009)
	140	0.176	

Уобичајено се претпоставља да је материјал језгра диска линеарно еластичан, изотропан (Табела 7.4). Прстен диска се обично моделује линеарним еластичним изотропним затезањем само са еластичним влакнима (Табела 7.5). Треба нагласити да се ове вредности односе на нуклеус и анулус који је здрав, што значи да није дошло до дегенерације.

Табела 7.4 Преглед материјалних карактеристика коришћених у моделима нуклеуса лумбалног диска

Материјални модел	E [MPa]	ν	Референца
<i>солид са карактеристикама флуида, линеарно еластичан, изотропан</i>	1	0.499	(Ruberté, Natarajan and Andersson 2009, Kurutz and Oroszváry, 2010, Zhang, et al. 2009)
	4	0.499	(Li and Wang 2006, Hassan, et al. 2020)
	10	0.4	(Chen, et al. 2008)
<i>Нестишљив флуид</i>			(Little, Percy and Adam 2008, Zander, et al. 2006, Rohlmann, Zander and Schmidt, et al. 2006, Rohlmann, Zander and Bergmann, 2006)
<i>квази нестишљив Хипереластичан, неохуковски</i>			(Rohlmann, Burra, et al. 2007)
<i>Муни-Ривлин нестишљив Пороеластичан</i>			(Moramarco, et al. 2010)
			(Baroud, et al. 2003, Schmidt, et al. 2007)
	varied	0.17	(Malandrino, Planell and Lacroix 2009)
<i>Вискоеластичан солид Осмо-вискоеластичан</i>	1	0.45	(Williams, Natarajan and Andersson 2007)
	2	0.49	(Wang, et al. 2000)
	0.15	0.17	(Schroeder, et al. 2006)

Табела 7.5 Преглед материјалних карактеристика коришћених у моделима анулуса лумбалног диска

Материјални модел	Основна субстанца		Влакна		Референца
	E [MPa]	ν	E [MPa]	ν	
Линеарно еластичан, изотропна матрица, само затезање, еластична влакна	4	0.4	500	-	(Glema, et al. 2004)
	4	0.45	500	0.3	(Fagan, et al. 2002)
	4	0.45	400/500/300	0.3	(Kurutz and Oroszváry, 2010)
	4.2	0.45	450	-	(Zhong, et al. 2006, Goto, et al. 2002)
	4.2	0.45	175	-	(Chen, et al. 2001)

Дегенерација као последица старења обично почиње у нуклеусу који губи своју нестишљивост и постаје чвршћи током времена, што значи да се трансформише из течног у чврсти материјал. Овај облик дегенерације језгра може се моделовати коришћењем смањене вредности за Поасонов коефицијент и повећане вредности за Јангов модул (Kurutz and Oroszváry, 2012). Ова промена обично је праћена механизмом укрућења диска у целини и смањењем запремине језгра и повећањем запремине анулуса, као и смањењем висине диска. Многи геометријски модели дегенерисаног диска користе смањење висине диска (Kurutz and Oroszváry, 2012). У исто време, врши се пролапс анулуса, изазивајући истискивање материјала ван простора диска.

За разлику од дегенерације повезане са старењем, језгро може изгубити своју нестишљивост без икаквог укрућења или процеса промене запремине као последица неочекиваног оптерећења. У овом случају, нуклеус може да пукне и хидростатичка компресија престаје. Овај облик дегенерације језгра може се моделирати наглим смањењем Поасоновог односа са Јанговом модулом нуклеуса који остаје исти (Kurutz and Oroszváry, 2010). Ова промена се обично покреће или прати кидањем или извијањем унутрашњег анулуса, цепањем ануларних влакана, ломљењем завршних плоча или колапсом у кичми, у зависности од узраста у коме се појава дешава. Другим речима, случајни пролапс диска се такође може десити у младости. Ова ситуација се може моделовати изненадним оштећењем ткива са свим укљученим компонентама. Да би симулирали ефекат дегенерације на биомеханичку активност сегмента, аутори (Rohlmann, Zander and Schmidt, et al. 2006) развили су модел сегмента покрета лумбалног сегмента са различитим класама дегенерације диска у вези са узрастом. Уведене су три стопе дегенерације диска: блага, умерена и тешка дегенерација. У поређењу са здравим диском, три класе су биле 20%, 40% и 60% мање висине, респективно. У исто време како се висина диска смањује, тако се и дужина влакана прстена смањује померањем њихових нелинеарних кривих крутости. (Schmidt, Kettler, et al. 2007) потврдили су теорију да ће са повећањем дегенерације диска, унутрашњи притисак и напрезање диска такође смањити вероватноћу пролапса диска. Предложили су благу, умерену и тешку дегенерацију диска са смањењем висине за 16.5%, 49.5% и 82.5% и претпоставили пораст остеофитних формација са постепеном дегенерацијом. (Zhang, et al. 2009) моделовали су здрав диск и два дегенерисана степена херније, у сегменту симулације кретања Л4-Л5. За оцену 1, модул еластичности језгра диска

био је два пута већи од модула еластичности прстена неоштећеног модела, а Поасонов однос је имплементиран да буде исти као анулус, уз смањење висине диска за 20%. За степен 2, еластични модул анулуса је удвостручен и запремина анулуса влакна је смањена за 25%, а висина диска је смањена за 40%, узимајући у обзир истраживања (Rohlmann, Zander and Schmidt, et al. 2006). Kurutz и Oroszváry (2010) увели су пет класа дегенерације у вези са нивоом дегенерације почевши од здравих (1) до потпуно дегенерисаних (5) случајева, и моделовали су губитак хидростатичког стања у језгру смањењем Поасоновог односа ($\nu = 0.499, 0.45, 0.40, 0.35, 0.30$) и повећањем Јанговог модула ($E = 1, 3, 9, 27, 81$ МПа). Истовремено, користили су постепено повећање анулуса ($E = 4.0, 4.5, 5.0, 5.5, 6.0$ МПа) и постепено смањење Јанговог модула у сунђерастој кости пршљена ($E = 150, 125, 100, 75, 50$ МПа) и завршне плоче ($E = 10, 80, 60, 40, 20$ МПа). Померање у зависности од старости затезних модула језгра ($E = 0.4, 1.0, 1.6, 2.2, 2.8$ МПа) је моделовано коришћењем приступа идентификације параметара заснованог на *in-vivo* одређеном лумбалном издужењу од стране аутора (Kurutz, 2006).

На основу свега претходног изнетог, у моделу који је развијен у оквиру ове дисертације коришћени су следећи подаци (Табела 7.6). Поред тога, моделирано је смањење висине диска од 1.5mm за дегенерисани диск, што одговара смањењу висине диска за 40%, као што је коришћено у другим студијама различитих аутора (Rohlmann, Zander and Schmidt, et al. 2006, Schmidt, Kettler, et al. 2007, Zhang, et al. 2009, Kurutz and Oroszváry, 2010). Својства материјала за дегенерисани диск су постављена као Јангов модул еластичности тако да буде двоструко већи од модула у нормалном материјалу диска, док је Поасонов коефицијент остао исти. Такође, као део дегенеративног процеса, на структуру костију утиче смањење Јанговог модула еластичности у односу на здраве пршљенове. Ова претпоставка је усвојена на основу (Rohlmann, Zander and Schmidt, et al. 2006, Zhang, et al. 2009). Како за модел здравог пацијента, тако и за модел са дискус хернијом, усвојена је густина костију $\rho = 1.83 \text{ g/cm}^3$ (Wang, et al. 2019), а густина материјала диска $\rho = 1 \text{ g/cm}^3$ (Glema, et al. 2004, Wang, et al. 2019).

Табела 7.6 Резиме коришћених материјалних карактеристика

	Кост		Диск	
	E [MPa]	ν	E [MPa]	ν
Модел са здравим диском	12	0.3	4	0.45
Модел са дискус хернијом	10	0.3	8	0.45

7.2. Задата оптерећења

У моделирању методом коначних елемената, фаза оптерећења сегмената лумбалног дела кичме зависи од циљева студије и врсте анализе. Испитани сегмент је обично чврсто ослоњен на доњу завршну плочу најнижих пршљенова од интереса, тако да се оптерећења углавном примењују на горњу завршну плочу највиших пршљенова од интереса. Оптерећења се могу користити као статичка или динамичка оптерећења. Константна статичка оптерећења или квазистатичка оптерећења која се постепено померају се обично користе у анализи лумбалне кичме. Најчешће коришћени типови оптерећења су сила или померање, како би се опонашало оптерећење или померање сегмената.

Chen, et al. (2001) користили су 10 Nm за флексију, експанзију, бочно савијање и аксијалну торзију са преднапрезањем од 150N у проучавању синдрома круте фиксације суседног сегмента. Goto, et al. (2002) су нумерички проучавали лумбалне пршљенове Л4-5 пресека користећи инструменте за постепено оптерећење да би применили интрадискални притисак у језгру. У десет корака извршено је компресионо оптерећење при 294N, након чега су уследила оптерећења савијања и екстензије од 15Nm у 15 корака. Притисак између дискова је постављен на 1.32 МПа за савијени и стојећи положај; тада је за положај исправљених леђа постављен је притисак на 0.6 МПа, а за модел дегенерисаног диска претпостављен је нулти притисак. Schmidt, Kettler, et al. (2007) користили су оптерећење у облику задатог момента од 7.5Nm са различитим правцима оптерећења између сваког пара главних анатомских равни за моделирање варијација анатомских оптерећења, нпр. ротација са бочним савијањем, итд. Оба ова случаја оптерећења су додатно повезана са аксијалним притиском предоптерећења од 500N. Chen, et al. (2008) испитивали су стратегије фузије и фиксације између тела додавањем притиска предоптерећења од 150N заједно са четири различита облика момената од 10Nm који симулирају догађаје физичког оптерећења. Zhang, et al. (2009) тестирали су пренос оптерећења система динамичке стабилизације под компресијом применом аксијалне силе притиска од 2000N да би се извршила валидација модела, као и притисак од 1000N да би се анализирао својства преноса оптерећења различитих имплантата.

Због веће нумеричке стабилности решења, када се користе померања као оптерећење, а не силе у софтверу ПАК, усвојена је препорука (Baroud, et al. 2003) који су применили померање у анализи оптерећења моделираног сегмента Л4-Л5, применом квазистатичког оптерећења компресије од 2.8mm са корацима од 0.2mm. У оквиру дисертације коришћена је иста методологија применом 2.8 mm у 10 временских корака.

7.3. Тип анализе

Коштано ткиво је основни елемент кичменог стуба и састоји се од везивних ткива које има две компоненте: ћелије и међућелијски материјал. Основно хемијско једињење међућелијског материјала и унутрашњи састав влакнастих материјала одређују крутост као кључну особину коштаног ткива. Кост је функционално ткиво са иреверзибилним биохемијским модификацијама и стога представља стални механизам за ремоделирање, ресорпцију и формирање ткива. Хомеостазу коштаног ткива регулишу системски хормони и хормони паратиroidних жлезда. Свако одступање у ресорпцији и развоју коштаног ткива (поремећај хомеостазе) доводи до значајних компликација и губитка есенцијалне функције костију.

Дакле, овде су примењена општа правила нумеричких симулација система (Milasinovic, Vukicevic and Filipovic 2020). Такође, могу се користити и једначине статичке или динамичке равнотеже. Структура костију се обично моделује помоћу 3Д коначних елемената да би се ухватила геометрија кости, а једначина 7.1 описује динамичко кретање за 3Д коначни елемент (Којић, et al. 2008):

$$\mathbf{M}^{n+1}\ddot{\mathbf{U}} + {}^n\mathbf{K}\mathbf{U} = {}^{n+1}\mathbf{F}^{\text{ext}} \quad 7.1$$

где су \mathbf{M} и ${}^n\mathbf{K}$ матрице масе и крутости елемената, ${}^{n+1}\ddot{\mathbf{U}}$ и \mathbf{U} вектори чворног убрзања и померања, и ${}^{n+1}\mathbf{F}^{\text{ext}}$ спољна чворна сила која укључује структурне спољне силе и дејство околних елемената.

Једначина кретања се односи на временски корак 'n' где горњи леви индекси 'n' и 'n+1' представљају почетак и крај временског корака, респективно. Матрица крутости се може написати у облику (Којић, et al. 2008):

$${}^n\mathbf{K} = \int_V \mathbf{B}^T {}^n\mathbf{C} \mathbf{B} dV \tag{7.2}$$

где је \mathbf{B} матрица деформација и померања и ${}^n\mathbf{C}$ конститутивна матрица.

У случају изотропног материјала, конститутивна матрица је дата у једначини 7.3, где су еластичне константе E и ν . Горњи леви индекс 'n' се користи да означи да се аксијални модул, који одговара брзини деформације може користити када су ефекти брзине значајни.

$$\mathbf{C} = \frac{E(1-\nu)}{(1+\nu)(1-2\nu)} \begin{bmatrix} 1 & \frac{\nu}{(1-\nu)} & \frac{\nu}{(1-\nu)} & 0 & 0 & 0 \\ \frac{\nu}{(1-\nu)} & 1 & \frac{\nu}{(1-\nu)} & 0 & 0 & 0 \\ \frac{\nu}{(1-\nu)} & \frac{\nu}{(1-\nu)} & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1-2\nu}{2(1-\nu)} & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1-2\nu}{2(1-\nu)} & 0 \\ 0 & 0 & 0 & 0 & 0 & \frac{1-2\nu}{2(1-\nu)} \end{bmatrix} \tag{7.3}$$

Хрскавица се сматра порозним деформабилним медијумом чије су поре испуњене течностима. Конфигурација у тренутку t , је означена са ${}^t\mathbf{V}$. Координате материјалне тачке P се означавају као ${}^t\mathbf{x}$, где горњи леви индекс означава време t . Физичке величине у материјалној тачки су: померање чврстог тела \mathbf{u} , релативна брзина флуида у односу на чврсто тело (Дарсијева брзина) \mathbf{q} , притисак флуида p , притисак надувавања p_c или електрични потенцијал ϕ . Затим се изводе основне једначине за претходно описани спрегнути проблем (Којић, et al. 2008). Најпре се разматра једначина равнотеже за чврсто тело:

$$(1-n)\mathbf{L}^T \boldsymbol{\sigma}_s + (1-n)\rho_s \mathbf{b} + \mathbf{k}^{-1} n \mathbf{q} - (1-n)\rho_s \ddot{\mathbf{u}} = 0 \tag{7.4}$$

где је $\boldsymbol{\sigma}_s$ - напон у чврстој фази, n - порозност, \mathbf{k} - матрица пермеабилности, ρ_s - густина чврстог тела, \mathbf{b} - запреминска сила по јединици масе, \mathbf{q} - релативна брзина флуида, $\ddot{\mathbf{u}}$ - убрзање чврстог тела. \mathbf{L}^T оператор је дефинисан као (Којић, et al. 2008):

$$\mathbf{L}^T = \begin{bmatrix} \frac{\partial}{\partial x_1} & \mathbf{0} & \mathbf{0} & \frac{\partial}{\partial x_2} & \mathbf{0} & \frac{\partial}{\partial x_3} \\ \mathbf{0} & \frac{\partial}{\partial x_2} & \mathbf{0} & \frac{\partial}{\partial x_1} & \frac{\partial}{\partial x_3} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \frac{\partial}{\partial x_3} & \mathbf{0} & \frac{\partial}{\partial x_2} & \frac{\partial}{\partial x_1} \end{bmatrix} \quad 7.5$$

Једначина 7.4 одговара тренутној конфигурацији ${}^t\mathbf{B}$; временски индекси се користе у ознакама само тамо где је неопходно ради јасноће. Једначина равнотеже за флуидну фазу је (без електрокинетичке спреге):

$$n\nabla p + n\rho_f \mathbf{b} - \mathbf{k}^{-1}n\mathbf{q} - n\rho_f \dot{\mathbf{v}}_f = \mathbf{0} \quad 7.6$$

Где је: p - притисак течности у порама, ρ_f - је густина течности и $\dot{\mathbf{v}}_f$ - убрзање флуида. Једначина 7.6 је позната као генерализовани Дарсијев закон и након низа трансформација се може написати као:

$$-\nabla p + \rho_f \mathbf{b} - \mathbf{k}^{-1} \mathbf{q} - \rho_f \ddot{\mathbf{u}} - \frac{\rho_f}{n} \dot{\mathbf{q}} = \mathbf{0} \quad 7.7$$

Следећа једначина је конститутивна релација за чврсто тело:

$$\boldsymbol{\sigma}' = \mathbf{C}^E (\mathbf{e} - \mathbf{e}_p) \quad 7.8$$

где је \mathbf{C}^E - еластична конститутивна матрица чврстих тела, \mathbf{e} - укупна деформација, а \mathbf{e}_p - деформација чврстог тела услед дејства притиска флуида (Filipovic 1999) која се дефинише као:

$$\mathbf{e}_p = -\frac{\mathbf{m}}{3K_s} p \quad 7.9$$

где је K_s - запремински модул чврстих зрна.

Међутим, у случају великих померања користе се друге мере деформације у конститутивном односу. Једна од најчешће коришћених мера деформације је логаритамска деформација (која се назива и природна деформација). Даља извођења претпостављају велика померања и велике деформације чврстог, као и еластичног материјала са конститутивном релацијом. Ефекти „swelling“ притиска су представљени кроз електрокинетичку спрегу. Друге могућности приказивања „swelling“ притиска могу се сматрати посебним случајевима у даљој дискусији. Применом принципа виртуелног рада и уз претпоставку да је материјал еластичан добијамо:

$$\begin{aligned} & \int_{{}^tV} \delta \mathbf{e}^T \mathbf{C}^E \mathbf{e} dV + \int_{{}^tV} \delta \mathbf{e}^T \left(\frac{\mathbf{C}^E \mathbf{m}}{3K_s} - \mathbf{m} \right) p dV + \int_{{}^tV} \delta \mathbf{u}^T \rho \ddot{\mathbf{u}} dV + \int_{{}^tV} \delta \mathbf{u}^T \rho \dot{\mathbf{q}} dV \\ & = \int_{{}^tV} \delta \mathbf{u}^T \rho \mathbf{b} dV + \int_{{}^tA} \delta \mathbf{u}^T \mathbf{t} dA \end{aligned} \quad 7.10$$

Даље, применом Галеркинове методе, тј. множењем интерполационом матрицом за релативну брзину флуида \mathbf{q} и интегрисањем са запремином коначног елемента tV добијамо:

$$\begin{aligned}
 & - \int_{tV} \mathbf{H}_q^T \nabla p dV + k_{11}^{-1} k_{12} \int_{tV} \mathbf{H}_q^T \nabla \phi dV + \int_{tV} \mathbf{H}_q^T \rho \mathbf{b} dV - k_{11}^{-1} \int_{tV} \mathbf{H}_q^T \mathbf{q} dV - \\
 & \int_{tV} \mathbf{H}_q^T \rho \ddot{\mathbf{u}} dV - \int_{tV} \mathbf{H}_q^T \frac{\rho_f}{n} \dot{\mathbf{q}} dV = \mathbf{0}
 \end{aligned} \tag{7.11}$$

Аналогно томе, множењем једначине континуитета интерполационом матрицом притиска флуида (која је вектор колона), добијамо:


$$\int_{tV} \mathbf{H}_p^T \nabla^T \mathbf{q} dV + \int_{tV} \mathbf{H}_p^T \left(\mathbf{m}^T - \frac{\mathbf{m}^T \mathbf{C}^E}{3K_s} \right) \dot{\mathbf{e}} dV + \int_{tV} \mathbf{H}_p^T \left(\frac{1-n}{K_s} + \frac{n}{K_f} - \frac{\mathbf{m}^T \mathbf{C}^E \mathbf{m}}{9K_s^2} \right) \dot{p} dV = \mathbf{0} \tag{7.12}$$

Коначно, множењем једначине континуитета интерполационом матрицом за електрични потенцијал и интегрисањем са запремином коначног елемента tV добијамо:

$$k_{21} \int_{tV} \mathbf{H}_\phi^T \nabla^T \nabla p dV - k_{22} \int_{tV} \mathbf{H}_\phi^T \nabla^T \nabla \phi dV = \mathbf{0} \tag{7.13}$$

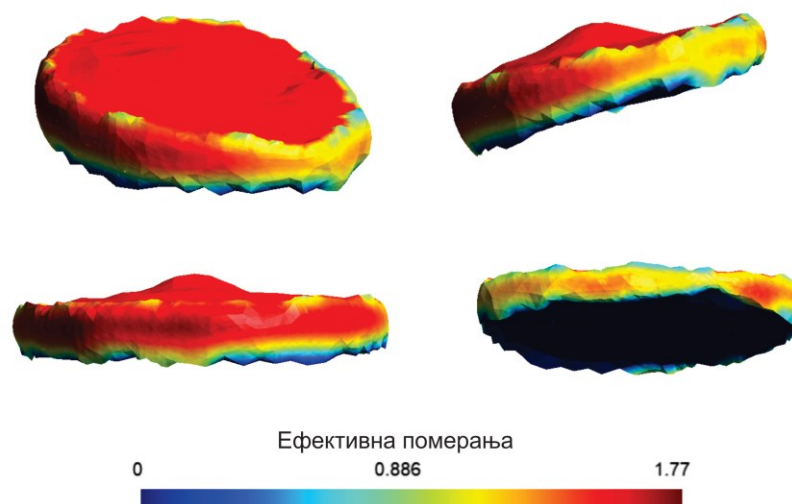
7.4. Резултати анализе методом коначних елемената

Ефективна померања области од интереса су илустрована на следећој слици (Слика 7.4), укључујући здрав лумбални и хернирани лумбални диск Л4/Л5. Примећује се да су померања за хернирани диск (2.1mm) већи него код нормалног диска (максимално 1.77mm), што је и разумљиво обзиром на чињеницу да део диска лежи изван стегнутог подручја између пршљенова (Šušteršič, и други 2022). Вредности напона код херније диска су такође биле веће од оних код нормалног.



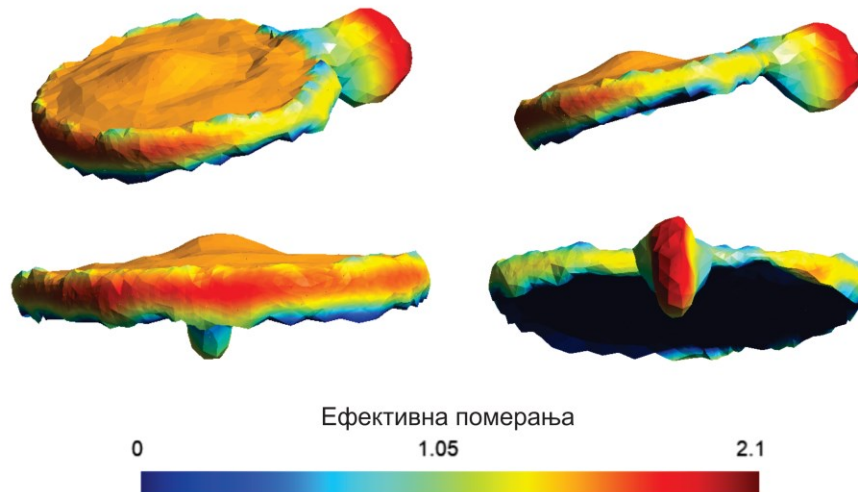
Слика 7.4 Поређење ефективних померања здравог (лево) и хернираног (десно) Л4/Л5 лумбалног диска

Детаљаним увидом у вредности ефективних померања нормалног здравог диска из неколико погледа, могу се видети ефективна померања која су означена црвеном бојом (1.77mm померања) (Слика 7.5). Те вредности су присутне на врху Л4/Л5 диска, што је и очекивано, јер Л4 пршљен притиска диск из тог правца. Вредности се смањују према кичменом каналу (око 1.0 mm).



Слика 7.5 Детаљан приказ ефективних померања здравог Л4/Л5 лумбалног диска у више погледа


Насупрот томе, ефективна померања за хернирани диск показују већу максималну вредност (2.1 mm) у односу на здрав диск (Слика 7.6). Ова вредност је присутна у пределу унутар кичменог канала, изван интервертебралног простора, означена црвеном бојом (2.1mm). Овај резултат је очекиван, јер се овај део диска помера изван интервертебралног простора.



Слика 7.6 Детаљан приказ ефективних померања хернираног лумбалног диска у више погледа


Узимајући у обзир померања у правцу x и y осе, за здрав диск пре херније, максимална вредност у правцу x осе је 1.19mm, а у правцу y осе је 1.19mm (Слика 7.7). Треба напоменути да на наредним сликама, пршљенови нису укључени у приказ померања, већ су обојени само зеленом бојом да би приказали положај диска између два пршљена. Резултати материјала диска у правцу x осе показују највећу вредност према кичменом каналу, што указује на почетак херније и померање материјала диска ван интервертебралног простора. Слични резултати су присутни

и за правац у осе са највећом вредношћу од 1.31mm. Све ово је указивало на почетак херније и померања материјала диска ка кичменом каналу.



Слика 7.7 Померања здравог Л4/Л5 диска у x правцу (а) и у правцу (б)

С обзиром на померања у правцу x и у осе, за хернирани диск максимална вредност у правцу x осе је 1.25mm, а у правцу y осе је 1.48mm, што представља више вредности у поређењу са здравим диском (Слика 7.8). Резултати материјала диска у правцу x осе показују највећу вредност према кичменом каналу, што указује на највеће помаке материјала ка кичменом каналу, док су за y смер највеће вредности за подручје херније, јер померање тог пресека није било ограничено на било који начин (кичмену мождина није укључена у симулацију). Овај део би вршио притисак на кичму и изазивао би бол у леђима. Будућа анализа се може заснивати на истраживању већег броја случајева хернијације и њихове разлике у померањима како би се повезале вредности померања са нивоом бола код пацијената.

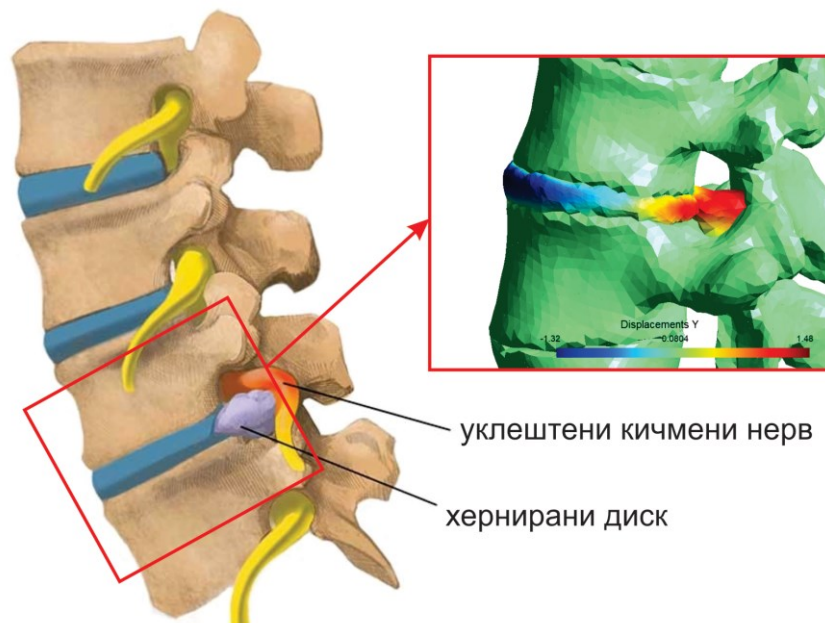


Слика 7.8 Померања хернираног Л4/Л5 диска у x правцу (а) и у правцу (б)

Већина студија истражује напрезања и силе у дисковима/пршљенова, под различитим оптерећењима. Међутим, да би се узела у обзир геометријска кретања материјала диска, медицински стручњаци често предлажу померања као карактеристику која би пружила додатне информације. Li и Wang (2006) стога испитују везу између сила оптерећења и максималног померања нумеричког модела. Иако се њихови резултати не могу директно упоредити са резултатима

овог истраживања, а на основу њихових резултата да су се под оптерећењем од 500N – 2500N максимална померања кретала од 0.5mm до 2.2mm, може се закључити да су и резултати добијени овим истраживањем у датом опсегу. Они такође имплицирају да задњи део диска има већу тенденцију за истискивање од других. Овај закључак се поклапа са запажањима о пацијенту спроведеног у оквиру овог истраживања, показујући да је постериорно-латерални део диска регион где анулусно влакно углавном пуца и долази до екструзије нуклеуса. Xie, et al. (2017) такође разматрају померања фиброзног прстена (mm) која је за различите моделе и различите типове оптерећења (флексија, екстензија, савијање) била истог реда величине као у овом истраживању и то у распону од 0.2mm до 2.989mm. Дистрибуција померања је такође у складу са резултатима нашег истраживања. Сличан налаз потврђују Du, et al. (2016).

Све ово показује да метода коначних елемената може да пружи додатне информације у анализи кичмених проблема и повезаности видљивог ефекта херније (тј. болова у леђима) (Слика 7.9) и померања материјала диска уз помоћ нумеричких симулација. Такве информације могу бити значајно од помоћи у одређивању адекватне терапије.



Слика 7.9 Повезаност бола услед укљештења нерва као последица дискус херније (лево) и нумеричка симулација хернираног диска (десно)

7.5. Спрезање компјутерског моделирања и машинског учења

Ово поглавље се умногоме ослања на методе машинског учења за аутоматску детекцију и сегментацију области од интереса на сликама магнетне резонанце, посебно области диска. Примена метода вештачке интелигенције је неопходна да би се детектовао и издвојио регион диска који се касније може даље анализирати. На основу те анализе могуће је да се издвоје геометријски параметри од интереса који би указали на материјалне карактеристике дискус херније. Главно ограничење био је мали број пацијената (било је доступно 10 пацијената са сликама у DICOM

формату), а самим тим и мали број слика (нису све слике биле са хернијом диска, већ су биле и укључене слике попречних пресека здравих дискова). Ово може резултирати потцењивањем површине области хернираних подручја. Међутим, представљена методологија показује обећавајуће резултате и може се применити када је доступан већи број слика.

Поред тога, представљена је методологија за компјутерско моделирање коришћењем методе коначних елемената за одређивање померања и напона у креираном 3Д моделу пршљенова (Л3, Л4 и Л5) и интервертебралних дискова (Л3/Л4, Л4/Л5 и Л5/С1). Да би се пратиле разлике између здравог појединца и појединца са дискус хернијом, истражена су два 3Д модела (диск хернија је била на нивоу Л4/Л5 за болесног пацијента). Резултати су показали да протрузија диска, услед померања, врши притисак на кичму и може да укаже на области са већим вредностима напона, као и како те вредности утичу на нпр. бол у људском телу. Иако етиологија лумбалне дискус херније и њен однос са болом у доњем делу леђа укључује сложену комбинацију механичких и биолошких процеса, Cai, et al. (2020), рапортирају да је абнормално повећање оптерећења зглобова у пршљенским сегментима на нивоу Л4-Л5 вероватно узрок болова у леђима. Будућа истраживања се могу фокусирати на испитивање већег броја случајева херније и њихове разлике у померањима како би се повезале вредности померања са нивоом бола код пацијената. На тај начин лекари могу имати помоћ при преписивању адекватне терапије. Главно ограничење ове студије је то што није било могуће реконструисати и разликовати сунђерасту и кортикалну кост, као ни материјал нуклеуса и анулуса. Број слика по пацијенту и резолуција слика нису били довољни да се прецизно разликују различити материјали. С друге стране, већина других аутора користи упрошћене моделе, за разлику од модела у овој докторској дисертацији, који је реконструисан на основу слика пацијента. Такви модели специфични за пацијенте могу се даље користити у будућим анализама креирања параметарског модела.

Додатно, спрезање машинског учења и компјутерског моделирања може се извести на такав начин да се креира 3Д параметарски модел за три испитивана пршљена и интервертебралне дискове и персонализује на основу резултата анализе слика са магнетне резонанце помоћу машинског учења. Релевантни параметри на основу слика са магнетне резонанце биће прослеђени параметарском моделу и биће креиран 3Д персонализовани параметарски модел. Даља истраживања напрезања и померања могу се користити не само у дијагностиковању већ и у преписивању адекватне терапије. Ово ће бити предмет будућих истраживања, а ово поглавље представља први корак у постизању овако сложених спрегнутих модела машинског учења и нумеричког моделирања.

8. ЗАКЉУЧНА РАЗМАТРАЊА

У оквиру ове докторске дисертације извршена је имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба. Анализирани су снимци са магнетне резонанце и сигнали ослањања снимљени мерном платформом. Извршено је поређење добијених резултата модела са златним стандардом, дефинисаним кроз експертско мишљење, односно дијагнозу лекара, са експерименталним мерењима, као и са резултатима из литературе. Сви модели поседују одређена ограничења у пружању информација, али су показали задовољавајућу тачност и представљају напредак у односу на постојеће резултате најновијих истраживања.

Са једне стране, у оквиру докторске дисертације, развијена је методологија и предложен је аутоматизовани приступ у дијагностици херније лумбалног диска коришћењем MR слика у аксијалној и сагиталној равни. Циљ је био да се развије систем за подршку одлучивању који ће помоћи лекарима како у погледу тачности успостављања дијагнозе, тако и по питању брзине доношења одлуке. Скуп података се састојао од комбинованог скупа података из јавно доступне базе и локално прикупљених слика у Клиничком центру Крагујевац, што је резултирало са 1169 сагиталних и 557 аксијалних слика. Предложена методологија се састојала од неколико кључних корака:

1. Први корак је био да се аутоматски детектују и сегментирају L4/L5 и L5/S1 кичмени дискови користећи U-net конволуциону неуронску мрежу, при чему је постигнута висока тачност у обема равнима – аксијалној (Дајс је био 0.961, Јакардов коефицијент сличности је био 0.925) и сагиталној (Дајс је био 0.897, Јакардов коефицијент сличности је био 0.813).
2. У другом кораку извршено је додатно процесирање добијених резултујућих слика након сегментације - CLAHE филтер је коришћен за побољшање квалитета и контраста сегментираних региона, а гранични оквир је екстрахован како би био прослеђен у коначну класификацију.
3. У последњем кораку сваки исечени регион са кичменим диском класификован је на основу креиране конволуционе неуронске мреже у класе (здрава, испупчење, централна, десна или лева хернија за аксијалну раван и здрав, L4/L5, L5/S1 ниво херније у сагиталној равни). Тачност класификације била је 0.87 на аксијалним и 0.91 на сагиталним сликама, док је тачност била 0.8 када је коришћен комбиновани аксијални и сагитални приказ.

У поређењу са вредностима тачности у литературним изворима, резултати добијени у овој дисертацији су показали приближно исту или чак бољу тачност, посебно имајући у виду да је извршена вишеулазна и вишекласна класификација. Ипак, постоји неколико ограничења ове предложене методологије. Коришћени скуп података је прилично мали за стандардну употребу дубоких конволуционих мрежа. Такође, скуп података је укључивао слике са нивоима протрузије, екструзије и секвестрације херније, тако да није могла да се изврши подела скупа података на

још мање подскупове, пошто је главни фокус био да се идентификују нивои (Л4/Л5 или Л5/С1) и страна херније (лева, десна, централна, испупчење).

С друге стране, у овој докторској дисертацији истраживана је и примена посебно дизајниране хардверске платформе за мерење силе, како би се ухватио „феномен“ слабости мишића стопала, који потиче од притиска нерва у кичмени канал услед хернијације. Након снимања сигнала, извршена је имплементација неколико различитих класификационих алгоритама (логистичка регресија, стабло одлучивања, случајне шуме, наивни Бајес, метода потпорних вектора, К најближих суседа), заједно са различитим методама нормализације, у сврху дијагностиковања дискус херније на нивоима Л4/Л5 или Л5/С1, на левој или десној страни. Добијени резултати показују да неки нелинеарни класификатори као што су стабла одлучивања или наивни Бајес показују бољу тачност у односу на друге класификаторе, а неке методе нормализације показују чак 10% већу тачност у поређењу са осталима. Развијена методологија се може применити за успешно разликовање здравих испитаника од испитаника са дискус хернијом. Поред тога, ова методологија се показала успешном у дијагностици побољшања слабости мишића након хируршке операције или физикалне терапије. Мотивација за одабир ових алгоритама је њихова једноставност имплементације на јефтним чиповима за постизање обраде сигнала у реалном времену на лицу места. Главна предност примењене методологије и дизајниране платформе је стварање јединственог, али јефтиног и неинвазивног система који може да постигне специфичну дијагностику болести ван болнице, смањујући време чекања и служећи као систем подршке медицинском особљу у доношењу одлука.

Како је доношење одлуке лекара о коначној дијагнози засновано на мануелном мишићном тесту и стручном знању, које се може преточити у базу АКО-ОНДА правила, тада је погодно користити и неки једноставнији алгоритам попут фази логике, уколико не постоји други начин за креирање математичког модела за описивање феномена. Систем заснован на мерењима са плочама мора да буде повезан са лаптопом или десктоп рачунаром, са адекватном апликацијом са којом би лекар требало да се упозна и да научи је користити. Ови главни недостаци су били мотивација за примену ФПГА у обради добијених сигнала. Резултати показују да систем прилагођен фази логици постиже задовољавајуће резултате како за преоперативну дијагностику, тако и детектује побољшања након операције и физикалне терапије. Генерално, систем је показао 93.1% тачности и веома високо подударане између Матлаб и ФПГА излаза (94.2% подударане за стање пре операције и 100% подударане за услове после операције и после физикалне терапије). Неки резултати погрешне класификације су се јавили услед проблема при мерењу, вероватно због лошег подешавања сензора на стопалима пацијента.

Поред тога, извршена је нумеричка анализа оптерећења интервертебралног диска коришћењем методе коначних елемената. Креирани модели су укључили здраву особу (без дискус херније) и особу са дискус хернијом, а симулирани су Л3, Л4 и Л5 пршљенови, као и интервертебрални дискови. Показано је да су ефективна померања за хернирани диск већа од померања за здрав диск и то у делу диска где је дошло до пролапса, што указује на највеће помаке материјала ка кичменом каналу и објашњава притисак на кичму и изазивани бол у леђима. Овакве нумеричке симулације могу да помогну у бољем разумевању појаве бола у леђима као последица лумбалне дискус херније.

Закључци добијени током истраживања за ову докторску дисертацију показују да се коришћењем система заснованог на вештачкој интелигенцији за дијагнозу дискус херније, постижу велике тачности сегментације и класификације, као и детекције побољшања стања након операције и физикалне терапије. Ови резултати упућују на могућност имплементације предложеног система у клиничкој пракси као помоћно средство које ће дати подршку медицинским стручњацима у клиничком доношењу одлука у вези са дијагнозом дискус херније.

На основу спроведених истраживања у оквиру ове докторске дисертације, будући рад ће бити усмерен на:

- увећања базе података пацијената (како слика магнетне резонанце, тако и сигнала ослањања),
- испитивање других алгоритама за семантичку сегментацију и детекцију и класификацију (различите архитектуре неуронске мреже),
- развој модела који се могу користити у учењу са преносом знања (енгл. *transfer learning*) на друге скупове података прикупљених за дискус хернију, што ће омогућити даљи развој и побољшање тачности у области дијагностике дискус херније,
- имплементација нових модела у систем подршке дијагностици који ће бити независан од компјутера, и који ће имати специјално дизајниран чип конфигурисан за дијагнозу дискус херније,
- испитивање различитих метахеуристичких алгоритама за избор модела,
- испитивање других методологија за дизајн хибридног модела (комбинација анализе слике и сигнала ослањања),
- развој сложених спрегнутих модела машинског учења и нумеричких сумулација,
- имплементацију предложеног система у клиничкој пракси.

Поред дискус херније, која је примарно била предмет истраживања ове докторске дисертације, могућност коришћења представљених алгоритама и у другим случајевима и проблемима кичменог стуба, представља главни допринос ове докторске дисертације. Будућа истраживања ће бити заснована на испитивању могућности коришћења представљених алгоритама за дијагнозу дискус херније на другим болестима кичменог стуба, као и генерисању универзалних закључака за сложеније случајеве где постоји више од једне дијагнозе.

ЛИТЕРАТУРА

- Adebayo, J., Gilmer, J., Muelly, M., Goodfellow, I., Hardt, M., & Kim, B. (2018). Sanity checks for saliency maps. *Advances in neural information processing systems*, 31.
- Ahn, U., Ahn, N., Buchowski, J., Garrett, E., Sieber, A., & Kostuik, J. (2000). Cauda equina syndrome secondary to lumbar disc herniation: a meta-analysis of surgical outcomes. *Spine*, 25(12), 1515-1522.
- Al Nezari, N. H., Schneiders, A. G., & Hendrick, P. A. (2013). Neurological examination of the peripheral nervous system to diagnose lumbar spinal disc herniation with suspected radiculopathy: a systematic review and meta-analysis. *The Spine Journal*, 13(6), 657-674.
- Al-Kafri, A. S., Sudirman, S., Hussain, A., Al-Jumeily, D., Natalia, F., Meidia, H., & ... Al-Jumaily, M. (2019). Boundary delineation of MRI images for lumbar spinal stenosis detection through semantic segmentation using deep neural networks. *IEEE Access*, 7, 43487-43501.
- Alomari, R. S., Corso, J. J., Chaudhary, V., & Dhillon, G. (2014). Lumbar spine disc herniation diagnosis with a joint shape model. *Computational Methods and Clinical Applications for Spine Imaging*, (87-98). Springer, Cham.
- Ayed, I. B., Punithakumar, K., Garvin, G., Romano, W., & Li, S. (2011). Graph cuts with invariant object-interaction priors: application to intervertebral disc segmentation. *Biennial International Conference on Information Processing in Medical Imaging*, (221-232). Springer, Berlin, Heidelberg.
- Balamurugan, N., Jothi, M., & Harikumar, R. (2012). FPGA Synthesis of SIRM Fuzzy System-Classification of Diabetic Epilepsy Risk Level. *Procedia engineering*, 38, 391-404.
- Baroud, G., Nemes, J., Heini, P., & Steffen, T. (2003). Load shift of the intervertebral disc after a vertebroplasty: a finite element study. *European Spine Journal*, 12(4), 421-426.
- Barriga, A., Sánchez-Solano, S., Brox, P., Cabrera, A., & Baturone, I. (2006). Modelling and implementation of fuzzy systems based on VHDL. *International Journal of Approximate Reasoning*, 41(2), 164-178.
- Best, R., & Begg, R. (2006). Overview of Movement Analysis and Gait Features. *Y Computational Intelligence for Movement Sciences: Neural Networks and Other Emerging Techniques*, 1st ed (1-69). Atlanta, GA, USA: Idea Group.
- Bhole, C., Kompalli, S., & Chaudhary, V. (2009). Context sensitive labeling of spinal structure in MR images. *Medical Imaging 2009: Computer-Aided Diagnosis; International Society for Optics and Photonics*, 7260, 72603P.
- Bloice, M. D., Roth, P. M., & Holzinger, A. (2019). Biomedical image augmentation using Augmentor. *Bioinformatics*, 35(21), 4522-4524.
- Bloice, M., Stocker, C., & Holzinger, A. (2017). Augmentor: an image augmentation library for machine learning. *arXiv, arXiv preprint*, 1708.04680.

- Boden, S., Davis, D., T.S., D., & al., e. (1990). Lumbar spine in asymptomatic subjects: A prospective investigation. *The Journal of Bone & Joint Surgery*, 72, 403–407.
- Bogduk, N. (2016). Functional anatomy of the spine. *Y Handbook of clinical neurology (Vol. 136) (675-688)*. Elsevier.
- Bonato, P. (2003). Wearable sensors/systems and their impact on biomedical engineering. *IEEE Eng Med Biol Mag*, 22, 18–20.
- Boustani, H. N., Zander, T., Disch, A. C., & Rohlmann, A. (2011). Pedicle-screw-based dynamic implants may increase posterior intervertebral disc bulging during flexion. *Biomed Tech (Berl)*, 56(6), 327-331.
- Brown, S., Francis, R., J, R., & Vranesic, Z. (1992). *Filed Programmable Gate Arrays*. Springer Science & Business Media.
- Cai, X. Y., Sun, M. S., Huang, Y. P., Liu, Z. X., Liu, C. J., Du, C. F., & Yang, Q. (2020). Biomechanical effect of L4–L5 intervertebral disc degeneration on the lower lumbar spine: a finite element study. *Orthopaedic Surgery*, 12(3), 917-930.
- Cai, Y., Landis, M., Laidley, D. T., Kornecki, A., Lum, A., & Li, S. (2016). Multi-modal vertebrae recognition using transformed deep convolution network. *Computerized medical imaging and graphics*, 51, 11-19.
- CDC. (2016). *Diabetes Public Health Resource*. (Diabetes DDT) Прейзето November 7, 2017 ca <https://www.cdc.gov/diabetes/home/index.html>
- Chen, C. S., Cheng, C. K., Liu, C. L., & Lo, W. H. (2001). Stress analysis of the disc adjacent to interbody fusion in lumbar spine. *Medical Engineering and Physisc*, 23(7), 483-491.
- Chen, H., Dou, Q., Yu, L., Qin, J., & Heng, P. A. (2018). VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images. *NeuroImage*, 170, 446-455.
- Chen, S., Tai, C., Lin, C., Hsieh, P., & Chen, W. (2008). Biomechanical comparison of a new stand-alone anterior lumbar interbody fusion cage with established fixation techniques – a three-dimensional finite element analysis. *BMC Musculoskeletal Disorders*, 9(88), 1-10.
- Chevrefils, C., Chériet, F., Grimard, G., & Aubin, C. E. (2007). Watershed segmentation of intervertebral disk and spinal canal from MRI images. In . *International Conference Image Analysis and Recognition*, (1017-1027). Springer, Berlin, Heidelberg.
- Chou, R., Fu, R., Carrino, J., & Deyo, R. (2009). Imaging strategies for low-back pain: systematic review and meta-analysis. *The Lancet*, 373(9662), 463-472.
- Chowdhury, S., & Saha, H. (2010). Development of a FPGA based fuzzy neural network system for early diagnosis of critical health condition of a patient. *Computers in biology and medicine*, 40(2), 190-200.
- Chowdhury, S., Chakrabarti, D., & Saha, H. (2008). FPGA realization of a smart processing system for clinical diagnostic applications using pipelined datapath architectures. *Microprocessors and Microsystems*, 32(2), 107-120.
- Cintra, E., Pimenta, T., & Moreno, R. (2011). The use of fuzzy clustering and correlation to implement a heart disease diagnosing system in FPGA. *Journal of Software Engineering and Applications*, 4(8), 491-496.

- Clinic, M. (2022). *Herniated lumbar disc*. Преузето 24.02.2022. ca <https://mayfieldclinic.com/pe-hldisc.htm>
- Clinic, M. (2022). *Spine anatomy*. Преузето 24.02.2022. ca <https://mayfieldclinic.com/pe-anat spine.htm>
- Clinical Centre of Kragujevac*. (2020). Преузето December 21, 2020 ca <https://www.kc-kg.rs/>
- Corso, J. J., Raja'S, A., & Chaudhary, V. (2008). Lumbar disc localization and labeling with a probabilistic model on both pixel and object features. In . *International Conference on Medical Image Computing and Computer-Assisted Intervention*, (202-210). Springer, Berlin, Heidelberg.
- Cummins, J., Lurie, J. D., Tosteson, T., Hanscom, B., Abdu, W. A., Birkmeyer, N. J., & ... Weinstein, J. (2006). Descriptive epidemiology and prior healthcare utilization of patients in the spine patient outcomes research trial's (sport) three observational cohorts: disc herniation, spinal stenosis and degenerative spondylolisthesis. *Spine*, 31(7), 806.
- Dou, Q., Yu, L., Chen, H., Jin, Y., Yang, X., Qin, J., & Heng, P. A. (2017). 3D deeply supervised network for automated segmentation of volumetric medical images. *Medical image analysis*, 41, 10-54.
- Du, H. G., Liao, S. H., Jiang, Z., Huang, H. M., Ning, X. T., & Jiang, N. Y. (2016). Biomechanical analysis of press-extension technique on degenerative lumbar with disc herniation and staggered facet joint. *Saudi Pharmaceutical Journal*, 24(3), 305-311.
- Ebrahimzadeh, E., Fayaz, F., Ahmadi, F., & Nikravan, M. (2018). A machine learning-based method in order to diagnose lumbar disc herniation disease by MR image processing. *MedLife Open Access*, 1(1), 1.
- Fagan, M., Julian, S., Siddall, D., & Mohsen, A. (2002). Patient specific spine models. Part 1: finite element analysis of the lumbar intervertebral disc – a material sensitivity study. *Proceedings of the Institution of Mechanical Engineers, Part H*, 216(5), 299-314.
- Farda, N. A., Lai, J. Y., Wang, J. C., Lee, P. Y., Liu, J. W., & Hsieh, I. H. (2020). Sanders classification of calcaneal fractures in CT images with deep learning and differential data augmentation techniques. *Injury*.
- Fardon, D. F., Williams, A. L., Dohring, E. J., Murtagh, F. R., Rothman, S. L., & Sze, G. K. (2014). Lumbar disc nomenclature: version 2.0: Recommendations of the combined task forces of the North American Spine Society, the American Society of Spine Radiology and the American Society of Neuroradiology. *The Spine Journal*, 14(11), 2525-2545.
- Ferguson, S., & Steffen, T. (2003). Biomechanics of the aging spine. *European Spine Journal*, Suppl 2, S97-S103.
- Filipovic, N. (1999). Numerical solution of coupled problems of a deformable solid body and fluid flow (In Serbian). Kragujevac: Faculty of Mechanical Engineering, University of Kragujevac.
- Gaikwad, N., Tiwari, V., A, K., & Shivaprakash, N. (2019). Efficient FPGA Implementation of Multilayer Perceptron for Real-time Human Activity Classification. *IEEE Access*, 26696-26706.

- Galbusera, F., Casaroli, G., & Bassani, T. (2019). Artificial intelligence and machine learning in spine research. *JOR spine*, 2(1), e1044.
- Ghosh and Chaudhary. (2014). Supervised methods for detection and segmentation of tissues in clinical lumbar MRI. *Computerized medical imaging and graphics*, 38(7), 639-649.
- Ghosh, S., Raja'S, A., Chaudhary, V., & Dhillon, G. (2011). Composite features for automatic diagnosis of intervertebral disc herniation from lumbar MRI. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, (5068-5071).
- Gioftsidou, A., Malliou, P., Pafis, G., Beneka, A., Godolias, G., & Maganaris, C. (2006). The effects of soccer training and timing of balance training on balance ability. *European Journal of Applied Physics*, 96, 659–664.
- Glema, A., Lodygowski, T., Kakol, W., Ogurkowska, M., & Wierszycki, M. (2004). Modeling of intervertebral discs in the numerical analysis of spinal segment. *ECCOMAS*.
- Goto, K., Tajima, N., Chosa, E., Totoribe, K., Kuroki, H., Arizumi, Y., & Arai, T. (2002). Mechanical analysis of the lumbar vertebrae in a three-dimensional finite element method model in which intradiscal pressure in the nucleus pulposus was used to establish the model. *journal of orthopaedic science*, 7(2), 243-246.
- Greenberg, M. S. (2016). Spine and spinal cord. *Y Handbook of Neurosurgery. 8th Edition* (1102). New York Thieme.
- Greenberg, M. S., & Arredondo, N. (2001). *Handbook of neurosurgery (Vol. 1013)*. New York: Thieme.
- Gulli, A., & Pal, S. (2017). *Deep learning with Keras*. Packt Publishing Ltd.
- Hancock, M. J., Koes, B., Ostelo, R., & Peul, W. (2011). Diagnostic accuracy of the clinical examination in identifying the level of herniation in patients with sciatica. *Spine*, 36(11), E712-E719.
- Handayani, I. (2019). Application of K-Nearest Neighbor Algorithm on Classification of Disk Hernia and Spondylolisthesis in Vertebral Column. *Indonesian Journal of Information Systems*, 2(1), 57-66.
- Haq, R., Aras, R., Besachio, D. A., Borgie, R. C., & Audette, M. A. (2015). 3D lumbar spine intervertebral disc segmentation and compression simulation from MRI using shape-aware models. *International journal of computer assisted radiology and surgery*, 10(1), 45-54.
- Harun, N. F., Yusof, K. M., Jamaludin, M. Z., & Hassan, S. A. (2012). Motivation in problem-based learning implementation. *Procedia-Social and Behavioral Sciences*, 56, 233-242.
- Hassan, C. R., Lee, W., Komatsu, D. E., & Qin, Y. X. (2020). Evaluation of nucleus pulposus fluid velocity and pressure alteration induced by cartilage endplate sclerosis using a poro-elastic finite element analysis. *Biomechanics and Modeling in Mechanobiology*, 1-11.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (770-778).
- Hoad, C. L., & Martel, A. L. (2002). Segmentation of MR images for computer-assisted surgery of the lumbar spine. *Physics in Medicine & Biology*, 47(19), 3503.

- Horsfield, M. A., Sala, S., Neema, M., Absinta, M., Bakshi, A., Sormani, M. P., & ... Filippi, M. (2010). Rapid semi-automatic segmentation of the spinal cord from magnetic resonance images: application in multiple sclerosis. *Neuroimage*, *50*(2), 446-455.
- Hung, K., Zhang, Y., & Tai, B. (2004). Wearable Medical Devices for Tele-Home Healthcare. *Proceedings of 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEMBS '04)*, (pp. 5384–5387). San Francisco, CA, USA.
- Jackson, R. P., Cain Jr, J. E., Jacobs, R. R., Cooper, B. R., & McMANUS, G. E. (1989). The neuroradiographic diagnosis of lumbar herniated nucleus pulposus: II. A comparison of computed tomography (CT), myelography, CT-myelography, and magnetic resonance. *Spine*, *14*(2), 1362-1367.
- Jamaludin, A., Kadir, T., & Zisserman, A. (2017). SpineNet: automated classification and evidence visualization in spinal MRIs. *Medical image analysis*, *41*, 63-73.
- Jandrić, S., & Antić, B. (2006). Lumbalni bolni sindrom i degenerativna bolest diskusa. *Medicinski Pregled/Medical Review*, *59*.
- Jarvik, J., & Deyo, R. (2002). Diagnostic evaluation of low back pain with emphasis on imaging. *Annals of internal medicine*, *137*(7), 586-597.
- Jensen, M., Brant-Zawadzki, M., Obuchowski, N., Modic, M., Malkasian, D., & Ross, J. (1994). Magnetic resonance imaging of the lumbar spine in people without back pain. *New England Journal of Medicine*, *331*, 69–73.
- Jordan, J., Konstantinou, K., & O'Dowd, J. (2011). Herniated lumbar disc. *BMJ Clinical Evidence Archives*, *2009*, 1118.
- Jothi, M., Balamurugan, N., & Harikumar, R. (2014). Design and Implementation of VLSI Fuzzy Classifier for Biomedical Application. *International Journal of Innovative Research in Science, Engineering and Technology*, 2641-2648.
- Kambin, P. (2005). *Arthroscopic and Endoscopic Spinal Surgery: Text and Atlas*. New Jersey: Humana Press.
- Kerr, R. S., Cadoux-Hudson, T. A., & Adams, C. B. (1988). The value of accurate clinical assessment in the surgical management of the lumbar disc protrusion. *Journal of Neurology, Neurosurgery & Psychiatry*, *51*(2), 169-173.
- Koh, J., Scott, P. D., Chaudhary, V., & Dhillon, G. (2011). An automatic segmentation method of the spinal canal from clinical MR images based on an attention model and an active contour model. *2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, (1467-1471).
- Kojic, M., Filipovic, N., Živkovic, M., & Slavkovic, G. (2001). PAK-FS finite element program for fluid-structure interaction. Kragujevac, Serbia.
- Kovacevic, V. (2019). Анализа разлика у клиничком току и исходу оперативног лечења пацијената оболелих услед лумбалне дискус херније након стандардне и микродискектомије. Докторска дисертација, Крагујевац, Универзитет у Крагујевцу.

- Kovačević, V., Jovanović, N., Miletić-Kovačević, M., Nikolić, R., Peulić, M., Rotim, K., Sajko, T., Rasulić, L. (2017). Standard lumbar discectomy versus microdiscectomy-Differences in clinical outcome and reoperation rate. *Acta Clinica Croatica*, 56(3), 391-398.
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kurutz, M. (2006). Age-sensitivity of time-related in vivo deformability of human lumbar motion segments and discs in pure centric tension. *Journal of Biomechanics*, 39(1), 147-157.
- Kurutz, M., & Oroszváry, L. (2010). Finite element analysis of weightbath hydrotraction treatment of degenerated lumbar spine segments in elastic phase. *Journal of Biomechanics*, 43(3), 433-441.
- Kurutz, M., & Oroszváry, L. (2012). Finite element modeling and simulation of healthy and degenerated human lumbar spine. In *Finite Element Analysis: From Biomedical Applications to Industrial Developments* (p. 193).
- Kusiak, A. (2004). *Fuzzy Logic*. Iowa City: The University of Iowa.
- LeCun, Y., Bottou, L., Y, B., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, H., & Wang, H. (2006). Intervertebral disc biomechanical analysis using the finite element modeling based on medical images. *Computerized Medical Imaging and Graphics*, 30(6-7), 363-370.
- Lilford, R., Pauker, S., DA, B., & Chard, J. (1998). Decision analysis and the implementation of research findings. *BMJ*, 317(7155), 405-409.
- Lin, C. J., & Lee, C. Y. (2011). Implementation of a neuro-fuzzy network with on-chip learning and its applications. *Expert Systems and Applications*, 38(11), 673-681. doi:<https://doi.org/10.1016/j.eswa.2010.07.019>
- Lin, M., Chen, Q., & Yan, S. (2013). Network in network. *arXiv, preprint arXiv*, 1312.4400.
- Little, J., Percy, M., & Adam, C. (2008). Are coupled rotations in the lumbar spine largely due to the osseo-ligamentous anatomy? - a modeling study. *Computer Methods in Biomechanics and Biomedical Engineering*, 11(1), 95-103.
- Liu, L., Cheng, J., Quan, Q., Wu, F. X., Wang, Y. P., & Wang, J. (2020). A survey on U-shaped networks in medical image segmentations. *Neurocomputing*, 409, 244-258.
- Longo, U. G., Denaro, L., Spiezia, F., Forriol, F., Maffulli, N., & Denaro, V. (2011). Symptomatic disc herniation and serum lipid levels. *European Spine Journal*, 20(10), 1658-1662.
- Lord, M., Reynolds, D., & Hughes, J. (1986). Foot pressure measurement: a review of clinical findings. *Journal Biomedical Engineering*, 8(4), 283-294.
- Lu, J. T., Pedemonte, S., Bizzo, B., & al., e. (2018). Deep Spine: Automated lumbar vertebral segmentation, disc-level designation, and spinal stenosis grading using deep learning. *Machine Learning for Healthcare Conference*.

- Lu, J. T., Pedemonte, S., Bizzo, B., Doyle, S., Andriole, K. P., & Michalski, M. H. (2018). Deep Spine: Automated lumbar vertebral segmentation, disc-level designation, and spinal stenosis grading using deep learning. *Machine Learning for Healthcare Conference*, (403-419).
- Lumen. (2022). *Module 6: Overview of Bones & The Axial Skeleton*. (Human Anatomy and Physiology Lab) Преузето 22.02.2022. ca <https://courses.lumenlearning.com/ap1x94x1/chapter/the-vertebral-column/>
- Malandrino, A., Planell, J., & Lacroix, D. (2009). Statistical factorial analysis on the poroelastic material properties sensitivity of the lumbar intervertebral disc under compression, flexion and axial rotation. *Journal of Biomechanics*, 42(3), 341-348.
- Margolis, D., Knauss, J., Bilker, W., & Baumgarten, M. (2003). Medical conditions as risk factors for pressure ulcers in an outpatient setting. *Age Ageing*, 32, 259-264.
- Marquardt, G., Bruder, M., Theuss, S., Setzer, M., & Seifert, V. (2012). Ultra-long-term outcome of surgically treated far-lateral, extraforaminal lumbar disc herniations: a single-center series. *European Spine Journal*, 21(4), 660-665.
- Mbarki, W., Bouchouicha, M., Frizzi, S., Tshibas, F., Farhat, L. B., & Sayadi, M. (2020). Lumbar spine discs classification based on deep convolutional neural networks using axial view MRI. *Interdisciplinary Neurosurgery*, 22, 100837.
- Merali, Z., Wang, J., Badhiwala, J., Witiw, C., Wilson, J., & Fehlings, M. (2021). A deep learning model for detection of cervical spinal cord compression in MRI scans. *Scientific reports*, 11(1), 1-11.
- Michopoulou, S. K., Costaridou, L., Panagiotopoulos, E., Speller, R., Panayiotakis, G., & Todd-Pokropek, A. (2009). Atlas-based segmentation of degenerated lumbar intervertebral discs from MR images of the spine. *IEEE transactions on Biomedical Engineering*, 56(9), 2225-2231.
- Milasinovic, D., Vukicevic, A., & Filipovic, N. (2020). dfemtoolz: An open-source C++ framework for efficient imposition of material and boundary conditions in finite element biomedical simulations. *Computer Physics Communications*, 249, 106996.
- Milette, P. (2000). Classification, diagnostic imaging, and imaging characterization of a lumbar herniated disk. *Radiologic Clinics*, 38(6), 1267-1292.
- Mintz, Y., & Brodie, R. (2019). Introduction to artificial intelligence in medicine. *Minimally Invasive Therapy & Allied Technologies*, 28(2), 73-81.
- Mittal, S., Gupta, S., & Dasgupta, S. (2008). FPGA: An efficient and promising platform for real-time image processing applications. *National Conference On Research and Development In Hardware Systems (CSI-RDHS)*. Kolkata, India.
- Mobbs, R. J., Newcombe, R. L., & Chandran, K. N. (2001). Lumbar discectomy and the diabetic patient: incidence and outcome. *Journal of Clinical Neuroscience*, 8(1), 10-13.
- Moradi, S., Alizadehasl, A., & Dhooge, J. e. (2019). MFP-Unet: A Novel Deep Learning Based Approach for Left Ventricle Segmentation in Echocardiography. *Physica Medica*, 58-69.

- Moramarco, V., Palomar, A., Pappalettere, C., & Doblaré, M. (2010). An accurate validation of a computational model of human lumbosacral segment. *Journal of Biomechanics*, 43(2), 334-342.
- Murphy, D., Beynnon, B., Michelson, J., & Vacek, P. (2005). Efficacy of plantar loading parameters during gait in terms of reliability, variability, effect of gender and relationship between contact area and plantar pressure. *Foot Ankle Int*, 26(2), 171-179.
- Naqvi, U., & Sherman, A. I. (2020). *Muscle strength grading*. StatPearls Publishing LLC.
- Nedjah, N., da Silva, R. M., & de Macedo Mourelle, L. (2012). Compact yet efficient hardware implementation of artificial neural networks with customized topology. *Expert Syst Appl*, 39(10), 9191-9206. doi:<https://doi.org/10.1016/j.eswa.2012.02.085>
- Neubert, A., Fripp, J., & al, E. C. (2012). Automated detection, 3D segmentation and analysis of high resolution spine MR images using statistical shape models. *Physics in Medicine and Biology*, 57(24), 8357-8376.
- Neubert, A., Fripp, J., Engstrom, C., Walker, D., Weber, M. A., Schwarz, R., & Crozier, S. (2013). Three-dimensional morphological and signal intensity features for detection of intervertebral disc degeneration from magnetic resonance images. *Journal of the American Medical Informatics Association*, 20(6), 1082-1090.
- Nexys. (2008). *Reference Manual Nexys2*. Прейзето 15.05.2019. ca [.http://www.ece.umd.edu/class/enee245.F2016/nexys2_reference_manual.pdf](http://www.ece.umd.edu/class/enee245.F2016/nexys2_reference_manual.pdf)
- Nilosey, A. (2014). FPGA Based Diabetic Patient Health Monitoring Using Fuzzy Neural Network. *International Journal of Science and Research (IJSR)*, 394-396.
- Oktay, A. B., & Akgul, Y. S. (2011). Localization of the lumbar discs using machine learning and exact probabilistic inference. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, (158-165). Springer, Berlin, Heidelberg.
- Oliveira, D., de Souza Braga, A., & da Mota Almeida, O. (2010). Fuzzy logic controller implementation on a FPGA using VHDL. *Annual Meeting of the North American Fuzzy Information Processing Society*. Toronto, ON, Canada.
- Orsila, H., Kangas, T., Salminen, E., Hämmäläinen, T., & Hännikäinen, M. (2007). Automated Memory-Aware Application Distribution for Multi-Processor System-on-Chips. *Journal of Systems Architecture*, 53(11), 795-815.
- Osti, O., & Fraser, R. (1992). MRI and discography of annular tears and intervertebral disc degeneration. A prospective clinical comparison. *Bone & Joint Journal*, 74(3), 431-435.
- Pan, Q., Zhang, K., He, L., Dong, Z., Zhang, L., & Wu, X. e. (2021). Automatically Diagnosing Disk Bulge and Disk Herniation With Lumbar Magnetic Resonance Images by Using Deep Convolutional Neural Networks: Method Development Study. *JMIR medical informatics*, 9(5), e14755.
- Pekar, V., Bystrov, D., Heese, H. S., Dries, S. P., Schmidt, S., Grewer, R., & ... Van Muiswinkel, A. M. (2007). Automated planning of scan geometries in spine MRI scans. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, (601-608). Springer, Berlin, Heidelberg.

- Peng, B., Hao, J., Hou, S., Wu, W., Jiang, D., Fu, X., & Yang, Y. (2006). Possible pathogenesis of painful intervertebral disc degeneration. *Spine*, 31(5), 556-566.
- Periyasamy, R., Mishra, A., Anand, S., & Ammini, A. (2011). Preliminary investigation of foot pressure distribution variation in men and women adults while standing. *The Foot*, 21(3), 142-148.
- Peulić, A., Šušteršič, T., & Peulić, M. (2019). Non-invasive improved technique for lumbar disc hernia classification based on fuzzy logic. *Biomedical Engineering/Biomedizinische Technik*, 64(4), 421-428.
- Peulić, M. S. (2020). Примена платформе за одређивање површинске raspodele pritiska stopala у дијагностици и процени успешности хируршког лечења лумбалне дискус херније. Докторска дисертација, Београд, Универзитет у Београду-Медицински факултет.
- Peulić, M., Joković, M., Šušteršič, T., & Peulić, A. (2020). A Noninvasive Assistant System in Diagnosis of Lumbar Disc Herniation. *Computational and mathematical methods in medicine*, 6320126.
- Ramesh, A., Kambhampati, C., Monson, J., & Drew, P. (2004). Artificial intelligence in medicine. *Annals of the Royal College of Surgeons of England*, 86(5), 334.
- Raychev, R., Mtibaa, A., & Abid, M. (2005). VHDL modeling of a fuzzy coprocessor architecture. *Proceedings of International Conference on Computer Systems and Technologies*. Varna, Bulgaria.
- Razak, A. A., Zayegh, A., Begg, R., & Wahab, Y. (2012). Foot plantar pressure measurement system: A review. *Sensors*, 12(7), 9884-9912.
- Reyentovich, A., & Abdu, W. (2002). Multiple independent, sequential, and spontaneously resolving lumbar intervertebral disc herniations: a case report. *Spine*, 27(5), 549-553.
- Righesso, O., Falavigna, A., & Avanzi, O. (2012). Correlation between persistent neurological impairment and clinical outcome after microdiscectomy for treatment of lumbar disc herniation. *Neurosurgery*, 70(2), 390-397.
- Rohlmann, A., Bauer, L., Zander, T., Bergmann, G., & HJ, W. (2006). Determination of trunk muscle forces for flexion and extension by using a validated finite element model of the lumbar spine and measured in vivo data. *Journal of Biomechanics*, 39(6), 981-989.
- Rohlmann, A., Zander, T., & Bergmann, G. (2006). Spinal loads after osteoporotic vertebral fractures treated by vertebroplasty or kyphoplasty. *European Spine Journal*, 15(8), 1255-1264.
- Rohlmann, A., Zander, T., Schmidt, H., Wilke, H., & Bergmann, G. (2006). Analysis of the influence of disc degeneration on the mechanical behaviour of a lumbar motion segment using the finite element method. *Journal of Biomechanics*, 39(13), 2484-2490.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (234-241). Springer, Cham.

- Ruberté, L., Natarajan, R., & Andersson, G. (2009). Influence of single-level lumbar degenerative disc disease on the behavior of the adjacent segments - a finite element model study. *Journal of Biomechanics*, 42(3), 341-348.
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206-215.
- Sagaria, S. A. (2008). *Fuzzy logic design using VHDL on FPGA*. University Malaysia Perlis: School of Computer and Communication Engineering.
- Salehi, E., Khanbare, S., Yousefi, H., Sharpasand, H., & Sheyjani, O. S. (2019). Deep Convolutional Neural Networks for Automated Diagnosis of Disc Herniation on Axial MRI. *IEEE 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*.
- Schmidt, H., Kettler, A., Rohlmann, A., Claes, L., & Wilke, H.-J. (2007). The risk of disc prolapses with complex loading in different degrees of disc degeneration—a finite element analysis. *Clinical biomechanics*, 22, 988-998.
- Schmidt, S., Kappes, J., & al., B. M. (2007). Spine detection and labeling using a parts-based graphical model. *Information Processing in Medical Imaging*, 20, 122-133.
- Schmidt, S., Kappes, J., Bergtholdt, M., Pekar, V., Dries, S., Bystrov, D., & Schnörr, C. (2007). Spine detection and labeling using a parts-based graphical model. *Biennial International Conference on Information Processing in Medical Imaging*, (122-133). Springer, Berlin, Heidelberg.
- Schroeder, Y., Wilson, W., Huyghe, J., & Baaijens, P. (2006). Osmoviscoelastic finite element model of the intervertebral disc. *European Spine Journal*, 15(Suppl 3), 361-371.
- Selvaraju, R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. *Proceedings of the IEEE international conference on computer vision*, (618-626).
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint*, arXiv:1409.1556.
- Sosner, J. (2014). Chapter 17 - Patient with lumbar disc herniation. *Y Case Studies in Pain Management* (131-136). Cambridge University Press.
- Steffens, D., Hancock, M. J., Pereira, L. S., Kent, P. M., Latimer, J., & Maher, C. G. (2016). Do MRI findings identify patients with low back pain or sciatica who respond better to particular interventions? A systematic review. *European Spine Journal*, 25(4), 1170-1187.
- Suri, P., Rainville, J., Katz, J. N., Jouve, C., Hartigan, C., & Limke, J. e. (2011). The accuracy of the physical examination for the diagnosis of midlumbar and low lumbar nerve root impingement. *Spine*, 36(1), 63.
- Šušteršič, T., Kovačević, V., Ranković, V., Rasulić, L., & Filipović, N. (2022). Computational Modelling and Machine Learning Based Image Processing in Spine Research. In *Personalized Orthopedics* (441-501). Springer, Cham.

- Šušteršič, T., Milovanović, V., Ranković, V., & Filipović, N. (2020). A comparison of classifiers in biomedical signal processing as a decision support system in disc hernia diagnosis. *Computers in Biology and Medicine*, *125*, 103978.
- Šušteršič, T., Peulić, M., & Peulić, A. (2021). FPGA implementation of fuzzy medical decision support system for disc hernia diagnosis. *Computer Science and Information Systems*, *18*(3), 619-640.
- Šušteršič, T., Ranković, V., Kovačević, V., Milovanović, V., Rasulić, L., & Filipović, N. (2021). Machine Learning-based Image Processing in Support of Discus Hernia Diagnosis. *2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)*, (1-5).
- Sustersic, T., Rankovic, V., Milovanovic, V., Kovacevic, V., Rasulic, L., & Filipovic, N. (2022). Detecting Disc Herniation in Segmented Lumbar Spine Magnetic Resonance Images using Distinct Features. *12th International Conference on Information Society and Technology (ICIST 2022)*, (1-5). Kopaonik, Serbia.
- Šušteršič, T., Ranković, V., Peulić, M., & Peulić, A. (2019). An Early Disc Herniation Identification System for Advancement in the Standard Medical Screening Procedure Based on Bayes Theorem. *IEEE Journal of Biomedical and Health Informatics*, *24*(1), 151-159.
- Suthaharan, S. (2016). *Machine learning models and algorithms for big data classification*. Integr. Ser. Inf. Syst, 36.
- Suzani, A., Seitel, A., Liu, Y., Fels, S., Rohling, R. N., & Abolmaesumi, P. (2015). Fast automatic vertebrae detection and localization in pathological ct scans-a deep learning approach. *International conference on medical image computing and computer-assisted intervention*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., & Anguelov, D. e. (2015). Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Tang, J., Alelyani, S., & Liu, H. (2014). *Data classification: algorithms and applications*. *Data Mining and Knowledge Discovery Series*. CRC press.
- Tekscan. (2016). *Pressure Mapping, Force Measurement & Tactile Sensors*. Прейзето May 9, 2017 ca <http://www.tekscan.com/flexible-force-sensors>
- Trafimow, D., & Trafimow, J. (2016). The shocking implications of Bayes' theorem for diagnosing herniated nucleus pulposus based on MRI scans. *Cogent Medicine*, *3*(1), 1133270.
- Tsai, R. (1987). A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses. *IEEE Journal on Robotics and Automation*, *3*(4), 323-344.
- Unal, Y., Polat, K., Kocer, H. E., & Hariharan, M. (2015). Detection of abnormalities in lumbar discs from clinical lumbar MRI with hybrid models. *Applied Soft Computing*, *33*, 65-76.
- Vitosevic, F., Rasulic, L., & Medenica, S. M. (2019). Morphological Characteristics of the Posterior Cerebral Circulation: An Analysis Based on Non-Invasive Imaging. *Turkish neurosurgery*, *29*(5), 625-630.

- Vroomen, P. C., de Krom, M. C., & Knottnerus, J. A. (2000). Consistency of history taking and physical examination in patients with suspected lumbar nerve root involvement. *Spine*, 25(1), 91.
- Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., & ... Vercauteren, T. (2018). Interactive medical image segmentation using deep learning with image-specific fine tuning. *IEEE transactions on medical imaging*, 37(7), 1562-1573.
- Wang, J., Parnianpour, M., Shirazi-Adl, A., & Engin, A. (2000). Viscoelastic finite element analysis of a lumbar motion segment in combined compression and sagittal flexion. *Spine*, 25(3), 310-318.
- Wang, T., Cai, Z., Zhao, Y., Zheng, G., Wang, W., Qi, D., & Wang, Y. (2019). Development of a Three-Dimensional Finite Element Model of Thoracolumbar Kyphotic Deformity following Vertebral Column Decancellation. *Applied bionics and biomechanics*, Article ID 5109285.
- Wild, S., Roglic, G., Green, A., Sicree, R., & King, H. (2004). Global prevalence of diabetes: Estimates for the year 2000 and projections for 2030. *Diabetes Care*, 27, 1047–1053.
- Williams, J., Natarajan, R., & Andersson, G. (2007). Inclusion of regional poroelastic material properties better predicts biomechanical behaviour of lumbar discs subjected to dynamic loading. *Journal of Biomechanics*, 40(9), 1981-1987.
- Winn, H. (2016). *Youmans & Winn Neurological Surgery*. 7th ed. Elsevier.
- Xie, F., Zhou, H., Zhao, W., & Huang, L. (2017). A comparative study on the mechanical behavior of intervertebral disc using hyperelastic finite element model. *Technology and Health Care*, 25(S1), 177-187.
- Xilinx. (2002). *Digital Video & Image processing Xilinx solutions for Broadcast Chain*.
- Yan, C., & Ming, Z. (2010). Measurement of In-Shoe Plantar Triaxial Stresses in High-Heeled Shoes. *Proceeding of 2010 3rd International Conference on Biomedical Engineering and Informatics (BMEI)*, (1760–1763). Yantai, China.
- Yan, L., Yoshua, B., & Geoffrey, H. (2015). Deep learning. *Nature*, 521, 436–444.
- Zander, T., Rohlmann, A., Burra, N., & Bergmann, G. (2006). Effect of a posterior dynamic implant adjacent to a rigid spinal fixator. *Clinical Biomechanics*, 21(8), 767-774.
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). *Dive into deep learning*. arXiv preprint arXiv:2106.11342.
- Zhang, D., & Lu, G. (2003). A comparative study of curvature scale space and Fourier descriptors for shape-based image retrieval. *Journal of Visual Communication and Image Representation*, 14(1), 39-47.
- Zhang, H., & Zhu, W. (2019). The path to deliver the most realistic follower load for a lumbar spine in standing posture: a finite element study. *Journal of biomechanical engineering*, 141(3), 1-10.
- Zhang, Q., Bhalerao, A., & Hutchinson, C. (2017). Weakly-supervised evidence pinpointing and description. *International Conference on Information Processing in Medical Imaging* (210-222). Springer, Cham.

Zhang, Q., Zhou, Y., Petit, D., & Teo, E. (2009). Evaluation of load transfer characteristics of a dynamic stabilization device on disc loading under compression. *Medical Engineering and Physics*, 31(5), 533-538.

Zhong, Z., Wei, S., Wang, J., Feng, C., Chen, C., & Yu, C. (2006). Finite element analysis of the lumbar spine with a new cage using a topology optimization method. *Medical Engineering and Physics*, 28(1), 90-98.

Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (2921-2929).

Zhou, Y., Liu, Y., Chen, Q., Gu, G., & Sui, X. (2019). Automatic lumbar MRI detection and identification based on deep learning. *Journal of digital imaging*, 32(3), 513-520.

ПРИЛОЗИ

Прилог 1 - Статистичке мере сензитивности, специфичности и прецизности

Логистичка регресија

32-1 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.666667	0.466667
2	0.2	0.964286	0.5
3	0.571429	0.884615	0.571429
4	0.583333	0.904762	0.777778

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0.2	0.928571	0.333333
3	0.714286	0.961538	0.833333
4	0.666667	0.761905	0.615385

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.8888889	0.791667	0.615385
2	0.4	0.928571	0.5
3	0.5714286	0.923077	0.666667
4	0.75	0.952381	0.9

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.875	0.666667
2	1	0.964286	0.833333
3	0.857143	0.923077	0.75
4	0.75	0.952381	0.9

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

31-2 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.670139	0.768229	0.520216
2	0.5375	0.941964	0.623188
3	0.75	0.929087	0.740088
4	0.632813	0.885417	0.759375

zscore	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

norm	Сензитивност	Специфичност	Прецизност
1	0.708333	0.792969	0.561983
2	0.58125	0.928571	0.592357
3	0.727679	0.929087	0.734234
4	0.617188	0.885417	0.754777

scale	Сензитивност	Специфичност	Прецизност
1	0.704861	0.817708	0.591837
2	0.53125	0.946429	0.639098
3	0.705357	0.955529	0.810256
4	0.742188	0.85119	0.74026

range	Сензитивност	Специфичност	Прецизност
1	0.649306	0.865885	0.644828
2	0.75625	0.945313	0.711765
3	0.790179	0.917067	0.719512
4	0.768229	0.918155	0.842857

center	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

30-3 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.603448	0.780583	0.407428
2	0.497537	0.930443	0.588578
3	0.739972	0.932855	0.77033
4	0.640394	0.862343	0.75618

zscore	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

norm	Сензитивност	Специфичност	Прецизност
1	0.706486	0.799466	0.468299
2	0.531527	0.92532	0.587371
3	0.747361	0.95181	0.825175
4	0.638547	0.86549	0.759893

scale	Сензитивност	Специфичност	Прецизност
1	0.6481938	0.648194	0.456358
2	0.4955665	0.495567	0.62291
3	0.7026742	0.702674	0.795618
4	0.716133	0.716133	0.759304

range	Сензитивност	Специфичност	Прецизност
1	0.568966	0.868021	0.518713
2	0.719704	0.926502	0.661985
3	0.789937	0.911009	0.729844
4	0.749179	0.921319	0.863905

center	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

29-4 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.629256	0.776781	0.776781
2	0.495161	0.936139	0.936139
3	0.734965	0.936911	0.936911
4	0.635601	0.842704	0.842704

zscore	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

norm	Сензитивност	Специфичност	Прецизност
1	0.681922	0.799194	0.560144
2	0.535403	0.932791	0.58721
3	0.750173	0.940648	0.772878
4	0.63876	0.855952	0.717028

scale	Сензитивност	Специфичност	Прецизност
1	0.669041	0.810879	0.57019
2	0.511532	0.944463	0.621893
3	0.713076	0.945502	0.778896
4	0.717036	0.842185	0.721937

range	Сензитивност	Специфичност	Прецизност
1	0.63638	0.861576	0.632892
2	0.729758	0.936046	0.670793
3	0.776699	0.91768	0.717532
4	0.738894	0.901575	0.810957

center	Сензитивност	Специфичност	Прецизност
1	-	-	-
2	-	-	-
3	-	-	-
4	-	-	-

Стабла одлучивања

32-1 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0.2	0.928571	0.333333
3	0.714286	0.961538	0.833333
4	0.916667	0.904762	0.846154

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.958333	0.875
2	1	0.964286	0.833333
3	0.857143	0.923077	0.75
4	0.833333	0.952381	0.909091

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.833333	0.6
2	0.4	0.928571	0.5
3	0.857143	0.961538	0.857143
4	0.75	0.857143	0.75

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0.2	0.928571	0.333333
3	0.857143	0.923077	0.75
4	0.583333	0.809524	0.636364

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.958333	0.875
2	1	0.928571	0.714286
3	0.857143	0.923077	0.75
4	0.833333	1	1

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.875	0.7
2	1	0.928571	0.714286
3	0.571429	0.961538	0.8
4	0.833333	0.952381	0.909091

31-2 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.65625	0.809896	0.564179
2	0.21875	0.917411	0.321101
3	0.714286	0.959135	0.824742
4	0.888021	0.885417	0.815789

zscore	Сензитивност	Специфичност	Прецизност
1	0.770833	0.932292	0.810219
2	0.8875	0.949777	0.759358
3	0.848214	0.936298	0.781893
4	0.833333	0.952381	0.909091

norm	Сензитивност	Специфичност	Прецизност
1	0.65625	0.835938	0.6
2	0.39375	0.927455	0.492188
3	0.852679	0.960337	0.852679
4	0.744792	0.846726	0.735219

scale	Сензитивност	Специфичност	Прецизност
1	0.645833	0.817708	0.570552
2	0.1375	0.919643	0.234043
3	0.861607	0.923077	0.750973
4	0.666667	0.816964	0.675462

range	Сензитивност	Специфичност	Прецизност
1	0.802083	0.958333	0.878327
2	0.99375	0.929688	0.716216
3	0.857143	0.932692	0.774194
4	0.833333	0.995536	0.990712

center	Сензитивност	Специфичност	Прецизност
1	0.777778	0.867188	0.687117
2	0.9875	0.9375	0.738318
3	0.59375	0.945913	0.747191
4	0.794271	0.950893	0.902367

30-3 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.501642	0.79064	0.374617
2	0.207389	0.884138	0.263619
3	0.676284	0.9577	0.829521
4	0.842775	0.877121	0.820544

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.665846	0.926724	0.694349
2	0.873399	0.948571	0.772549
3	0.827938	0.919576	0.758054
4	0.833333	0.947318	0.913386

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.489737	0.836104	0.427599
2	0.355172	0.918916	0.466969
3	0.851161	0.95363	0.848177
4	0.741379	0.810892	0.723268

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.491379	0.812295	0.395572
2	0.1133	0.911626	0.204082
3	0.861013	0.912829	0.750383
4	0.672414	0.796114	0.687369

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.725369	0.949302	0.781513
2	0.972906	0.928768	0.732024
3	0.868403	0.926965	0.783492
4	0.832923	0.998221	0.996807

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.694171	0.869663	0.571091
2	0.974877	0.935764	0.752185
3	0.616467	0.936817	0.748079
4	0.787767	0.944171	0.90391

29-4 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.656855	0.785963	0.535063
2	0.261895	0.893995	0.306122
3	0.675058	0.954319	0.799141
4	0.807997	0.90168	0.824439

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.776232	0.911719	0.767294
2	0.831048	0.948711	0.743158
3	0.804579	0.937438	0.775908
4	0.833249	0.950182	0.905283

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.659364	0.83456	0.599129
2	0.322984	0.928226	0.445545
3	0.84519	0.958212	0.844849
4	0.745144	0.832095	0.71719

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.661694	0.790575	0.5423
2	0.061492	0.918757	0.119066
3	0.845363	0.922216	0.74529
4	0.664399	0.83221	0.693504

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.790479	0.940793	0.833518
2	0.943508	0.942375	0.745144
3	0.866935	0.932832	0.776534
4	0.830326	0.983103	0.965612

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.805623	0.860534	0.684162
2	0.960887	0.944664	0.756148
3	0.609101	0.949868	0.765871
4	0.781065	0.947216	0.894243

Метода потпорних вектора

32-1 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.875	0.666667
2	0.4	0.928571	0.5
3	1	0.961538	0.875
4	0.75	0.857143	0.75

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0.4	0.892857	0.4
3	0.714286	0.923077	0.714286
4	0.666667	0.904762	0.8

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.444444	0.666667	0.333333
2	0	0.964286	0
3	0	0.807692	0
4	0.583333	0.619048	0.466667

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.75	0.5
2	0.4	0.964286	0.666667
3	0.571429	0.884615	0.571429
4	0.666667	0.857143	0.727273

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.555556	0.75	0.454545
2	0.4	0.964286	0.666667
3	0.428571	0.846154	0.428571
4	0.666667	0.809524	0.666667

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.888889	0.916667	0.8
2	0.6	0.928571	0.6
3	0.714286	0.961538	0.833333
4	0.75	0.857143	0.75

31-2 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.690972	0.852865	0.637821
2	0.3875	0.928571	0.492063
3	0.946429	0.959135	0.861789
4	0.734375	0.866071	0.758065

zscore	Сензитивност	Специфичност	Прецизност
1	0.65625	0.783854	0.532394
2	0.40625	0.914063	0.457746
3	0.700893	0.911058	0.679654
4	0.666667	0.892857	0.780488

norm	Сензитивност	Специфичност	Прецизност
1	0.444444	0.675781	0.339523
2	0.04375	0.988839	0.411765
3	0.03125	0.794471	0.039326
4	0.583333	0.613095	0.46281

scale	Сензитивност	Специфичност	Прецизност
1	0.614583	0.74349	0.473262
2	0.3875	0.956473	0.613861
3	0.575893	0.883413	0.570796
4	0.669271	0.854167	0.723944

range	Сензитивност	Специфичност	Прецизност
1	0.552083	0.763021	0.466276
2	0.39375	0.950893	0.588785
3	0.428571	0.84976	0.434389
4	0.661458	0.802083	0.656331

center	Сензитивност	Специфичност	Прецизност
1	0.864583	0.895833	0.756839
2	0.58125	0.929688	0.596154
3	0.705357	0.96274	0.835979
4	0.734375	0.85119	0.73822

30-3 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.558703	0.826252	0.445645
2	0.372906	0.923941	0.495095
3	0.891274	0.949668	0.84349
4	0.716749	0.849206	0.760122

zscore	Сензитивност	Специфичност	Прецизност
1	0.490148	0.781301	0.359098
2	0.404433	0.916158	0.491029
3	0.684377	0.892804	0.660217
4	0.662767	0.862069	0.762096

norm	Сензитивност	Специфичност	Прецизност
1	0.323481	0.683087	0.203302
2	0.066995	0.976749	0.365591
3	0.055595	0.822553	0.087052
4	0.591133	0.557061	0.470819

scale	Сензитивност	Специфичност	Прецизност
1	0.428982	0.735222	0.288276
2	0.366995	0.950148	0.595524
3	0.575651	0.87342	0.580554
4	0.664204	0.828955	0.721355

range	Сензитивност	Специфичност	Прецизност
1	0.46757	0.764265	0.33149
2	0.37931	0.94197	0.566593
3	0.42646	0.865817	0.491684
4	0.656199	0.764231	0.649797

center	Сензитивност	Специфичност	Прецизност
1	0.77381	0.875718	0.60885
2	0.557635	0.924335	0.595789
3	0.693174	0.957057	0.830873
4	0.717365	0.81965	0.726158

29-4 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.713351	0.813138	0.588744
2	0.362742	0.932964	0.491424
3	0.861175	0.950775	0.824873
4	0.705847	0.874942	0.763327

zscore	Сензитивност	Специфичност	Прецизност
1	0.63237	0.777478	0.5159
2	0.39754	0.929097	0.500304
3	0.669067	0.892843	0.627007
4	0.658703	0.875182	0.750972

norm	Сензитивност	Специфичност	Прецизност
1	0.444848	0.694304	0.353044
2	0.07246	0.967281	0.283394
3	0.079263	0.812415	0.102142
4	0.592876	0.62692	0.475913

scale	Сензитивност	Специфичност	Прецизност
1	0.542025	0.73209	0.431394
2	0.351734	0.947127	0.542948
3	0.572984	0.870285	0.543225
4	0.657745	0.848742	0.713045

range	Сензитивност	Специфичност	Прецизност
1	0.543929	0.768061	0.467923
2	0.366129	0.944794	0.542187
3	0.425086	0.846456	0.427054
4	0.652671	0.792291	0.64229

center	Сензитивност	Специфичност	Прецизност
1	0.817137	0.862256	0.689885
2	0.541734	0.934922	0.597829
3	0.684937	0.958817	0.817441
4	0.709963	0.836943	0.713307

Наивни Бајес

32-1 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.555556	0.875	0.625
2	0.6	0.964286	0.75
3	0.857143	0.923077	0.75
4	0.833333	0.857143	0.769231

zscore	Сензитивност	Специфичност	Прецизност
1	0.888889	0.958333	0.888889
2	0.8	0.964286	0.8
3	0.857143	0.961538	0.857143
4	0.833333	0.904762	0.833333

norm	Сензитивност	Специфичност	Прецизност
1	0.444444	0.875	0.571429
2	0.8	0.892857	0.571429
3	0.714286	0.923077	0.714286
4	0.833333	0.904762	0.833333

scale	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0.8	0.964286	0.8
3	0.857143	0.961538	0.857143
4	0.666667	0.904762	0.8

range	Сензитивност	Специфичност	Прецизност
1	0.777778	0.916667	0.777778
2	0.4	0.964286	0.666667
3	0.571429	0.923077	0.666667
4	0.833333	0.761905	0.666667

center	Сензитивност	Специфичност	Прецизност
1	0.666667	0.916667	0.75
2	0.4	1	1
3	0.714286	0.923077	0.714286
4	0.916667	0.761905	0.6875

31-2 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.590278	0.860677	0.613718
2	0.56875	0.964286	0.739837
3	0.84375	0.915865	0.72973
4	0.8125	0.873512	0.785894

zscore	Сензитивност	Специфичност	Прецизност
1	0.864583	0.941406	0.846939
2	0.76875	0.96317	0.788462
3	0.821429	0.961538	0.851852
4	0.833333	0.895833	0.820513

norm	Сензитивност	Специфичност	Прецизност
1	0.493056	0.872396	0.591667
2	0.74375	0.902902	0.57767
3	0.75	0.932692	0.75
4	0.828125	0.89881	0.823834

scale	Сензитивност	Специфичност	Прецизност
1	0.628472	0.822917	0.570978
2	0.75	0.964286	0.789474
3	0.830357	0.939904	0.788136
4	0.710938	0.883929	0.777778

range	Сензитивност	Специфичност	Прецизност
1	0.71875	0.869792	0.674267
2	0.40625	0.96317	0.663265
3	0.450893	0.929087	0.63125
4	0.804688	0.729167	0.629328

center	Сензитивност	Специфичност	Прецизност
1	0.694444	0.904948	0.732601
2	0.4	0.986607	0.842105
3	0.709821	0.930288	0.732719
4	0.890625	0.779762	0.697959

30-3 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.385878	0.847291	0.38715
2	0.536453	0.960296	0.729893
3	0.82266	0.899871	0.714329
4	0.799466	0.850575	0.781031

zscore	Сензитивност	Специфичност	Прецизност
1	0.772989	0.931034	0.736986
2	0.723645	0.957143	0.771534
3	0.811752	0.957914	0.854444
4	0.833128	0.868363	0.808405

norm	Сензитивност	Специфичност	Прецизност
1	0.383415	0.87069	0.425706
2	0.685714	0.898621	0.574969
3	0.771992	0.955237	0.839969
4	0.822865	0.870826	0.809408

scale	Сензитивност	Специфичност	Прецизност
1	0.452381	0.818658	0.384106
2	0.693596	0.960887	0.780055
3	0.783603	0.924395	0.759291
4	0.712028	0.848933	0.758583

range	Сензитивност	Специфичност	Прецизност
1	0.541872	0.85078	0.475847
2	0.419212	0.956059	0.65613
3	0.393385	0.924395	0.612939
4	0.800287	0.673508	0.620366

center	Сензитивност	Специфичност	Прецизност
1	0.564039	0.90117	0.587933
2	0.390148	0.97468	0.755005
3	0.702322	0.915935	0.717727
4	0.869253	0.756705	0.704307

29-4 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.59431	0.835181	0.574865
2	0.51746	0.96502	0.725397
3	0.793635	0.910701	0.705255
4	0.795413	0.871112	0.779078

zscore	Сензитивност	Специфичност	Прецизност
1	0.816555	0.91975	0.792344
2	0.69379	0.961456	0.762711
3	0.792656	0.959639	0.840952
4	0.832913	0.876959	0.794586

norm	Сензитивност	Специфичност	Прецизност
1	0.54375	0.865667	0.602846
2	0.65379	0.911607	0.569112
3	0.772753	0.939276	0.774069
4	0.814382	0.88678	0.804314

scale	Сензитивност	Специфичност	Прецизност
1	0.596057	0.821858	0.55649
2	0.658629	0.966057	0.776036
3	0.778111	0.919936	0.723494
4	0.721909	0.860705	0.747569

range	Сензитивност	Специфичност	Прецизност
1	0.650963	0.826722	0.584853
2	0.429315	0.959029	0.651711
3	0.355069	0.92987	0.576829
4	0.783081	0.715092	0.610985

center	Сензитивност	Специфичност	Прецизност
1	0.70681	0.881695	0.691399
2	0.377379	0.975749	0.735366
3	0.696889	0.92248	0.70763
4	0.851596	0.803783	0.712647

К најближих суседа

32-1 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.541667	0.352941
2	0	0.964286	0
3	0.285714	0.884615	0.4
4	0.5	0.809524	0.6

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.444444	0.75	0.4
2	0	0.928571	0
3	0.142857	0.807692	0.166667
4	0.666667	0.666667	0.533333

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.444444	0.75	0.4
2	0	0.928571	0
3	0.142857	0.807692	0.166667
4	0.666667	0.666667	0.533333

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.555556	0.666667	0.384615
2	0	0.964286	0
3	0.142857	0.769231	0.142857
4	0.583333	0.761905	0.583333

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.444444	0.75	0.4
2	0	0.928571	0
3	0.142857	0.807692	0.166667
4	0.666667	0.666667	0.533333

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.666667	0.428571
2	0	0.964286	0
3	0.142857	0.884615	0.25
4	0.666667	0.714286	0.571429

31-2 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.544271	0.354244
2	0	0.997768	0
3	0.285714	0.844952	0.331606
4	0.492188	0.806548	0.592476

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.454861	0.733073	0.389881
2	0	0.930804	0
3	0.129464	0.800481	0.148718
4	0.632813	0.672619	0.524838

	Сензитивност	Специфичност	Прецизност
<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.454861	0.733073	0.389881
2	0	0.930804	0
3	0.129464	0.800481	0.148718
4	0.632813	0.672619	0.524838

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.569444	0.661458	0.386792
2	0	0.965402	0
3	0.142857	0.766827	0.141593
4	0.559896	0.761905	0.573333

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.454861	0.733073	0.389881
2	0	0.930804	0
3	0.129464	0.800481	0.148718
4	0.632813	0.672619	0.524838

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.659722	0.660156	0.421286
2	0	0.998884	0
3	0.169643	0.841346	0.223529
4	0.640625	0.720238	0.56682

30-3 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.504105	0.537664	0.214198
2	0	0.995369	0
3	0.283603	0.82598	0.331551
4	0.47147	0.77121	0.578735

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.206486	0.712644	0.152286
2	0	0.925714	0
3	0.117523	0.76783	0.133493
4	0.591954	0.625479	0.513076

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.206486	0.712644	0.152286
2	0	0.925714	0
3	0.119634	0.76783	0.135566
4	0.591954	0.6263	0.513624

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.373563	0.648604	0.209968
2	0	0.961872	0
3	0.146024	0.733455	0.142906
4	0.521346	0.724275	0.557629

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.206486	0.712644	0.152286
2	0	0.925714	0
3	0.119634	0.76783	0.135566
4	0.591954	0.6263	0.513624

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.495074	0.647783	0.260026
2	0	0.999409	0
3	0.191414	0.817734	0.242208
4	0.609195	0.682266	0.561059

29-4 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.672424	0.547992	0.358096
2	0	0.99506	0
3	0.281452	0.842269	0.324511
4	0.477873	0.802093	0.579795

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.478248	0.700672	0.374669
2	0.000161	0.934893	0.000442
3	0.113767	0.787671	0.126069
4	0.568011	0.687855	0.509763

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.477778	0.700773	0.374517
2	0.000161	0.934721	0.000441
3	0.117281	0.787547	0.129393
4	0.568212	0.689209	0.510938

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.581317	0.649782	0.383649
2	0.000161	0.964696	0.000815
3	0.150058	0.761934	0.145081
4	0.515205	0.764238	0.555304

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.477778	0.700773	0.374517
2	0.000161	0.934857	0.000442
3	0.117915	0.787547	0.130001
4	0.568212	0.689238	0.510961

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.654794	0.642633	0.407268
2	0	0.997869	0
3	0.200432	0.83187	0.242973
4	0.589331	0.732191	0.557025

Случајне шуме

32-1 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.555556	0.875	0.625
2	0.4	0.928571	0.5
3	0.857143	0.961538	0.857143
4	0.833333	0.809524	0.714286

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.958333	0.875
2	0.6	0.964286	0.75
3	0.857143	0.961538	0.857143
4	0.833333	0.809524	0.714286

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.555556	0.833333	0.555556
2	0.4	0.928571	0.5
3	0.857143	0.961538	0.857143
4	0.75	0.809524	0.692308

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.666667	0.791667	0.545455
2	0	0.928571	0
3	0.714286	0.923077	0.714286
4	0.75	0.809524	0.692308

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.958333	0.875
2	0.6	0.964286	0.75
3	1	0.961538	0.875
4	0.833333	0.857143	0.769231

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.777778	0.875	0.7
2	0.4	0.964286	0.666667
3	0.857143	0.961538	0.857143
4	0.833333	0.857143	0.769231

31-2 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.614583	0.822917	0.565495
2	0.39375	0.938616	0.533898
3	0.785714	0.949519	0.807339
4	0.799479	0.85119	0.7543

zscore	Сензитивност	Специфичност	Прецизност
1	0.819444	0.90625	0.766234
2	0.65	0.964286	0.764706
3	0.861607	0.951923	0.828326
4	0.833333	0.912202	0.844327

norm	Сензитивност	Специфичност	Прецизност
1	0.65625	0.829427	0.590625
2	0.325	0.934152	0.468468
3	0.785714	0.961538	0.846154
4	0.773438	0.821429	0.71223

scale	Сензитивност	Специфичност	Прецизност
1	0.618056	0.804688	0.542683
2	0.0875	0.944196	0.21875
3	0.848214	0.901442	0.698529
4	0.734375	0.83631	0.719388

range	Сензитивност	Специфичност	Прецизност
1	0.84375	0.945313	0.852632
2	0.65	0.964286	0.764706
3	0.955357	0.961538	0.869919
4	0.833333	0.897321	0.822622

center	Сензитивност	Специфичност	Прецизност
1	0.784722	0.859375	0.676647
2	0.60625	0.96875	0.776
3	0.700893	0.959135	0.82199
4	0.817708	0.863095	0.773399

30-3 подела			
Без нормализације	Сензитивност	Специфичност	Прецизност
1	0.401478	0.821531	0.359956
2	0.360099	0.932315	0.515515
3	0.774455	0.941208	0.800364
4	0.801314	0.809661	0.737299

zscore	Сензитивност	Специфичност	Прецизност
1	0.75821	0.890599	0.634054
2	0.649261	0.960197	0.765389
3	0.825123	0.950632	0.835709
4	0.833744	0.907362	0.857143

norm	Сензитивност	Специфичност	Прецизност
1	0.477833	0.819787	0.39863
2	0.266995	0.928768	0.428458
3	0.779733	0.955665	0.842586
4	0.79023	0.792693	0.717614

scale	Сензитивност	Специфичност	Прецизност
1	0.399425	0.813218	0.348371
2	0.097537	0.926601	0.209968
3	0.821956	0.889912	0.694411
4	0.749795	0.804735	0.719094

range	Сензитивност	Специфичност	Прецизност
1	0.758621	0.934421	0.743064
2	0.654187	0.96069	0.768964
3	0.941239	0.955344	0.865136
4	0.831691	0.887521	0.83135

center	Сензитивност	Специфичност	Прецизност
1	0.675287	0.849856	0.529279
2	0.561084	0.961478	0.744444
3	0.669951	0.954808	0.818573
4	0.823276	0.835112	0.76898

29-4 подела			
<i>Без нормализације</i>	Сензитивност	Специфичност	Прецизност
1	0.595542	0.817381	0.550141
2	0.370121	0.940531	0.526379
3	0.762673	0.946014	0.791819
4	0.795094	0.83533	0.733979

<i>zscore</i>	Сензитивност	Специфичност	Прецизност
1	0.828136	0.887886	0.734746
2	0.625363	0.965114	0.761963
3	0.823329	0.955265	0.832077
4	0.833384	0.913076	0.845645

<i>norm</i>	Сензитивност	Специфичност	Прецизност
1	0.654144	0.818574	0.574845
2	0.262984	0.93912	0.435468
3	0.761262	0.960577	0.83868
4	0.791851	0.815102	0.709911

<i>scale</i>	Сензитивност	Специфичност	Прецизност
1	0.579279	0.815113	0.540215
2	0.101613	0.929335	0.204313
3	0.814084	0.901062	0.688987
4	0.748606	0.828178	0.713437

<i>range</i>	Сензитивност	Специфичност	Прецизност
1	0.835193	0.930813	0.819065
2	0.648952	0.96502	0.768137
3	0.932863	0.959538	0.861249
4	0.831653	0.903015	0.830509

<i>center</i>	Сензитивност	Специфичност	Прецизност
1	0.776949	0.846027	0.654248
2	0.542056	0.966122	0.740743
3	0.662356	0.959336	0.814313
4	0.822446	0.852851	0.761555

БИОГРАФИЈА КАНДИДАТА

Тијана Шуштершич је рођена 31.05.1993. године у Крагујевцу, Република Србија. Основну школу "Мома Станојловић", у Крагујевцу, завршила је 2008. године, као носилац Вукове дипломе. Након завршетка основне школе уписала је Прву крагујевачку гимназију, природно-математички смер, коју је завршила 2012. године, такође као носилац Вукове дипломе.

Основне академске студије на Факултету инжењерских наука у Крагујевцу уписала је 2012. године, а завршила 2015. године, на смеру за Примењену механику и аутоматско управљање, са просечном оценом у току студија 10,00 (десет и 00/100). Након завршетка основних академских студија, 2015. године уписала је мастер академске студије на Факултету инжењерских наука, смер Машинско инжењерство, модул Примењена механика и аутоматско управљање. Мастер академске студије завршила је 2017. године са просечном оценом 10,00 (десет и 00/100). Основне и мастер академске студије завршила је као студент генерације. Током основних и мастер академских студија била је стипендиста Министарства просвете, науке и технолошког развоја за изузетно надарене ученике и студенте, као и Фонда за младе таленте "Доситеја". Током мастер академских студија била је и стипендиста Истраживачко развојног центра за биоинжењеринг (BioIRC), где је након завршетка студија засновала радни однос. Након завршених мастер академских студија уписала је докторске академске студије, школске 2017/2018. године, на Факултету инжењерских наука, Универзитета у Крагујевцу, и положила све предмете предвиђене планом и програмом, са просечном оценом 10.

Најпре је била запослена на Факултету инжењерских наука Универзитета у Крагујевцу као истраживач приправник од јула 2017. године на пројекту Министарства просвете, науке и технолошког развоја Републике Србије ОИ174028 „Методe моделирања на више скала са применама у биомедицини“. У јануару 2019. године изабрана је у звање асистента на Факултету инжењерских наука Универзитета у Крагујевцу, а радни однос на истом факултету засновала је марта 2019. године. Учествоје у реализацији наставе на Факултету инжењерских наука Универзитета у Крагујевцу на предметима: Рачунарски алати, Експертски системи, Компјутерска графика, Софтверски инжењеринг, Биоинжењеринг и биоинформатика, Рачунарска графика, Вештачка интелигенција, Интелигентно управљање и Аутоматско управљање, Неуронске мреже, Системи за подршку одлучивању, Виртуелна реалност.

У оквиру истраживања учествовала је на неколико билатералних пројеката, пројеката финансираних у оквиру COST програма, Horizont2020 (SGABU (бр. 952603), SILICOFCM (бр. 777204), PANBIORA (бр. 760921)) и CEI пројекту COVIDAI (бр. 305.6019-20). У оквиру ових пројеката се усавршавала кроз краће и дуже боравке у иностранству. Једна је од добитница Програма Националних стипендија L'Oréal – UNESCO „За жене у науци“ за 2021. годину. Објавила је 2 поглавља у монографијама категорије М11, као и преко 60 научних радова презентованих на међународним конференцијама (категирије М33 и М34), радове објављене у међународним часописима (категирије М20) као и радове у националним часописима (категирије М50).

ИЗЈАВА АУТОРА О ОРИГИНАЛНОСТИ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Ја, Тијана Шуштершич, изјављујем да докторска дисертација под насловом:

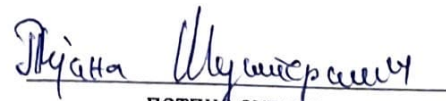
Имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба

која је одбрањена на Факултету инжењерских наука, Универзитета у Крагујевцу представља *оригинално ауторско дело* настало као резултат *сопственог истраживачког рада*.

Овом Изјавом такође потврђујем:

- да сам *једини аутор* наведене докторске дисертације,
- да у наведеној докторској дисертацији *нисам извршио/ла повреду* ауторског нити другог права интелектуалне својине других лица,
- да умножени примерак докторске дисертације у штампаној форми у чијем се прилогу налази ова Изјава садржи докторску дисертацију истоветну одбрањеној докторској дисертацији.

У Крагујевцу, 22.06.2022. године,


потпис аутора

**ИЗЈАВА АУТОРА О ИСТОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ
ДОКТОРСКЕ ДИСЕРТАЦИЈЕ**

Изјављујем да су штампана и електронска верзија докторске дисертације под насловом:

Имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала
као подршка одлучивању у дијагностици болести кичменог стуба истоветне.

У Крагујевцу, 22.06.2022. године,


потпис аутора

ИЗЈАВА АУТОРА О ИСКОРИШЋАВАЊУ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Ја, Тијана Шуштершич,

дозвољавам

не дозвољавам

Универзитетској библиотеци у Крагујевцу да начини два трајна умножена примерка у електронској форми докторске дисертације под насловом:

Имплементација алгоритама вештачке интелигенције у обради биомедицинских сигнала као подршка одлучивању у дијагностици болести кичменог стуба

и то у целини, као и да по један примерак тако умножене докторске дисертације учини трајно доступним јавности путем дигиталног репозиторијума Универзитета у Крагујевцу и централног репозиторијума надлежног министарства, тако да припадници јавности могу начинити трајне умножене примерке у електронској форми наведене докторске дисертације путем *преузимања*.

Овом Изјавом такође

дозвољавам

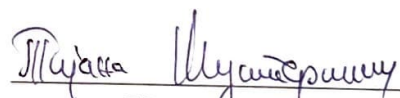
не дозвољавам¹

¹ Уколико аутор изабере да не дозволи припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од *Creative Commons* лиценци, то не искључује право припадника јавности да наведену докторску дисертацију користе у складу са одредбама Закона о ауторском и сродним правима.

припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од следећих *Creative Commons* лиценци:

- 1) Ауторство
- 2) Ауторство - делити под истим условима
- 3) Ауторство - без прерада
- 4) Ауторство - некомерцијално
- 5) Ауторство - некомерцијално - делити под истим условима
- 6) Ауторство - некомерцијално - без прерада²

У Крагујевцу, 22.06.2022. године,


потпис аутора

² Молимо ауторе који су изабрали да дозволе припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од *Creative Commons* лиценци да заокруже једну од понуђених лиценци. Детаљан садржај наведених лиценци доступан је на: <http://creativecommons.org.rs/>