

УНИВЕРЗИТЕТ У БЕОГРАДУ
ЕЛЕКТРОТЕХНИЧКИ ФАКУЛТЕТ

Иван А. Вајс

**ИНТЕЛИГЕНТНИ СИСТЕМИ ЗА ДЕТЕКЦИЈУ
ДИСЛЕКСИЧНИХ ОБРАЗАЦА ОЧНИХ
ПОКРЕТА ТОКОМ ЧИТАЊА НА СРПСКОМ
ЈЕЗИКУ**

докторска дисертација

Београд, 2023

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Ivan A. Vajs

**INTELLIGENT SYSTEMS FOR THE
DETECTION OF DYSLEXIC EYE MOVEMENT
PATTERNS DURING READING IN THE
SERBIAN LANGUAGE**

Doctoral Dissertation

Belgrade, 2023

Подаци о ментору и члановима комисије

Ментор:

др Милица Јанковић, ванредни професор

Универзитет у Београду – Електротехнички факултет

Чланови комисије:

др Горан Квашчев, ванредни професор

Универзитет у Београду – Електротехнички факултет

др Бошко Николић, редовни професор

Универзитет у Београду – Електротехнички факултет

др Вања Ковић, редовни професор

Универзитет у Београду – Филозофски факултет

др Андреј Савић, виши научни сарадник

Универзитет у Београду – Електротехнички факултет

др Владислава Крсмановић, научни сарадник

Иновациони центар Електротехничког факултета у Београду

Датум одбране: _____

Захвалница

Истраживање спроведено у оквиру ове дисертације је финансирано (2021-2023) кроз пројекте „Подршка остваривању заједничког интереса у научноистраживачкој делатности“ Министарства просвете, науке и технолошког развоја Републике Србије и „Подршка остваривању заједничког интереса у научноистраживачкој делатности“ Министарства науке, технолошког развоја и иновација.

Пре свега бих желео да се захвалим свим испитаницима који су учествовали у студији на основу које је реализована ова дисертација.

На првом месту желим да се захвалим свом ментору, проф. др Милици Јанковић, на великом труду, енергији, стрпљењу и саветима који су били кључни током спроведеног истраживања и израде ове дисертације.

Захваљујем се и великом броју колега који су учествовали у процесу чији је резултат ова дисертација. Захваљујем се проф. др Вањи Ковић, која ме је увела у нови начин размишљања и упознала са концептима експерименталне психологије. Захваљујем се др Андреју Савићу на корисним саветима током истраживања и на увиду у приступе примене биомедицинског инжењерства. Захваљујем се и др Тамари Папић, чије истраживање представља претечу ове дисертације, на енергији и оптимизму које уноси у научна истраживања. Захваљујем се и проф. др Горану Квашчеву на корисним саветима и смерницама везаним за неуралне мреже и пријатној сарадњи.

Желео бих да се захвалим и проф. др Дејану Драјићу, на уложеном труду, времену и стрпљењу за истраживачки рад који је значајно олакшао реализацију ове дисертације.

Захваљујем се и др Владислави Крсмановић, која је пратила мој истраживачки рад и била ту да испрати моје научне кораке. Захваљујем се колегиници мс Милици Баџи Атанасијевић на подршци и несебичном дељењу мишљења и оку за детаље који су за научна истраживања неопходни. Захваљујем се и мс Илији Радовановићу на пруженим условима за рад и увиду у то колико је значајна добра организација. Захваљујем се и колеги мс Петру Атанасијевићу на непресушном извору оптимизма и позитивизма у научном окружењу. Желим да се захвалим и др Милошу Јањићу на датом увиду у то колико истрајност и упорност имају утицаја на научне резултате.

Захваљујем се и проф. др Милошу Цветановићу и проф. др Бошку Николићу на пријатној дугогодишњој сарадњи и саветима. Желим да се захвалим и др Милици Ђурић-Јовичић на добрим смерницама током научне каријере.

Желим да се захвалим и др Војиславу Јовановићу на интересантним дискусијама и размени искустава у научним истраживањима.

Захваљујем се и колегама дипл. инж. Василију Ковачевићу и дипл. инж. Селени Богојевић на доброј енергији и увиду у другачију научну перспективу.

Хвала пријатељима на указаној подршци и стрпљењу, а посебно Предрагу за његове савете и подршку током студија. На крају, желим да се захвалим својој породици, мајци Сањи и оцу Александру на указаном стрпљењу и разумевању.

У Београду, септембар 2023. године

Иван Вајс

Интелигентни системи за детекцију дислексичних образаца очних покрета током читања на српском језику

Резиме – Дислексија негативно утиче на способност особе да флуентно чита и разуме прочитани текст, а различите манифестације и одсуство формалне дефиниције остављају простор за субјективност испитивача у успостављању дијагнозе. Праћење покрета очију омогућава директан увид у стратегију читања. У овој дисертацији је приказано неколико приступа за објективно успостављање дијагнозе дислексије код деце, које се ослањају на праћење покрета очију. Примарну базу података чине очни покрети 15 испитаника са дислексијом и 15 неуротипичних испитаника (7-13 год.), који су читали текстове на српском језику приказане на различитим бојама. Најпре су сигнали покрета очију ових испитаника искоришћени како би се развила нова обележја која карактеришу дислексичне тенденције. Обележја су коришћена за обучавање различитих традиционалних алгоритама машинског учења (максимална тачност од 94%), као и за евалуацију перформанси за различите боје приказа текста. Потом је примењен други приступ базиран на примени неуралних мрежа за детекцију дислексије уз минимално претпроцесирање сигнала покрета очију. Детекција дислексије је иницијално вршена на основу приказа покрета очију у форми слике помоћу конволуционе неуралне мреже. Затим је представљен и евалуиран алгоритам који се заснива на конволуционим аутоенкодерима, а за чију евалуацију је коришћена отворена база података очних покрета деце током читања на шведском језику. Развијени алгоритам је обучаван на примарној бази прикупљеној за српски језик, а евалуиран на бази прикупљеној за шведски језик, и обрнуто (тачност од 85,6% и 82,9%). Развијени алгоритми и њихова робусност представљају значајан искорак за објективно успостављање дијагнозе и евалуацију дислексије на основу очних покрета и применљиви су у различитим експерименталним условима.

Кључне речи: развојна дислексија, праћење покрета очију, читање, обрада сигнала, машинско учење, конволуциона неурална мрежа, аутоенкодер, класификација, статистичка анализа

Научна област: техничке науке, електротехника

Ужа научна област: биомедицинско инжењерство

УДК број: 621.3

Intelligent systems for the detection of dyslexic eye movement patterns during reading in the Serbian language

Abstract – Dyslexia negatively affects a person's ability to read fluently and understand the text, and various manifestations and the absence of a formal definition leave room for the examiner's subjectivity in establishing a diagnosis. Tracking eye movements allows direct insight into the reading strategy. This dissertation presents several approaches for objectively establishing the diagnosis of dyslexia in children, which rely on tracking eye movements. The primary database consists of 15 neurotypical and 15 subjects with dyslexia, aged 7 to 13, who read texts in Serbian displayed in different colors. Firstly, the eye movements of these subjects were used to develop new features that characterize dyslexic tendencies. The features were used to train different traditional machine learning algorithms (maximum accuracy of 94%), as well as to evaluate performance for different text display colors. Secondly, an approach involved the application of neural networks for the detection of dyslexia with minimal preprocessing was implemented. Dyslexia detection was initially performed based on the representation of eye movements in the form of an image using a convolutional neural network. Then, an algorithm based on convolutional autoencoders was presented and evaluated, and an open database of Swedish children's eye movements while reading was used for its evaluation. The developed algorithm was trained on the primary database collected for the Serbian language and evaluated on the database collected for the Swedish language, and vice versa (accuracy of 85.6% and 82.9%). The developed algorithms and their robustness represent a significant step forward for objective diagnosis and evaluation of dyslexia based on eye movements and are applicable in different experimental conditions.

Keywords: developmental dyslexia, eye-tracking, reading, signal processing, machine learning, convolutional neural network, autoencoder, classification, statistical analysis

Scientific area: technical sciences, electrical engineering

Specific scientific area: biomedical engineering

UDK number: 621.3

Садржај

Предговор	i
1 Увод.....	1
1.1 Дефиниција и заступљеност дислексије	1
1.2 Дијагноза дислексије	2
2 Биометријски приступи у дијагнози дислексије	4
2.1 Примена медицинског сликања у дијагнози дислексије	4
2.2 Примена електроенцефалографије у дијагнози дислексије	8
2.3 Примена праћења покрета очију у дијагнози дислексије	12
3 Разликовање дислексичних образаца применом метода статистичке анализе.....	18
4 Препознавање дислексичних образаца помоћу метода машинског учења	22
5 Терапија дислексије и асистивне технологије	26
6 База података.....	28
7 Детекција дислексије применом класификације обележја	31
7.1 Увод	31
7.2 Визуелизација података	31
7.3 Детекција дислексије на основу обележја изведених из фиксација и сакада	34
7.3.1 Метода	34
7.3.2 Резултати и дискусија	37
7.3.3 Закључак	43
7.4 Детекција дислексије у реалном времену	44
7.4.1 Метода	44
7.4.2 Резултати и дискусија	47
7.4.3 Закључак	52
8 Детекција дислексије применом конволуционих неуралних мрежа	53
8.1 Увод	53
8.2 Детекција дислексије помоћу <i>VGG16</i> мреже	55
8.2.1 Метода	55
8.2.2 Резултати и дискусија	59
8.2.3 Закључак	60
8.3 Робусна детекција дислексије помоћу конволуционог аутоенкодера	61

8.3.1	Метода.....	61
8.3.2	Резултати и дискусија	67
8.3.3	Закључак	70
9	Закључак	71
9.1	Научни доприноси докторске дисертације.....	71
9.2	Правци за даља истраживања	73
10	Прилог А – Пример слајдова коришћених у експерименту	75
11	Прилог Б – Визуелизација покрета очију током читања - база испитаника	77
12	Прилог В – Алгоритми машинског учења.....	87
13	Прилог Г – Метрике за евалуацију класификатора базираног на обележјима.....	89
14	Референце	92
15	Биографија.....	101

Списак слика

Слика 1. Преглед броја публикација које се баве дислексијом по годинама из два различита репозиторијума (<i>Scopus</i> и <i>PubMed</i> , септембар 2023).	2
Слика 2. Приказ локација ЕЕГ елелктрода у складу са опште прихваћеним 10-20 стандардом [55]. Приказ реализован помоћу <i>mne</i> библиотеке [56].....	9
Слика 3. Примери уређаја за праћење покрета очију. Сlike преузете из [67] и прилагођене.	12
Слика 4. Приказ поставке експеримента.	29
Слика 5. Приказ очних покрета једног испитаника са дислексијом и једног контролног испитаника у $x - y$ равни. А1 представља обичан приказ очних покрета контролног испитаника, Б1 обичан приказ очних покрета испитаника са дислексијом, А2 развијени приказ контролног испитаника и Б2 развијени приказ испитаника са дислексијом. Слика је преузета из [17] и допуњена.	33
Слика 6. Алгоритамски приказ обраде и анализе података за развијање и евалуацију обележја заснованих на фиксацијама и сакадама. Слика је преузета из [17] и прилагођена.	37
Слика 7. Рангирање зачаја обележја за потребе класификације дислексије засновано на <i>Gini importance</i> параметру <i>RF</i> алгоритма. Слика је преузета из [17] и прилагођена.	40
Слика 8. Прикази (А) коефицијента самопресека фиксација, (Б) варијабилности самопресека фиксација, (В) средње фракталне димензије фиксација за сваку конфигурацију боја и две групе субјеката. Слика је преузета из [17] и прилагођена.	41
Слика 9. Визуелни приказ података за све субјекте са дислексијом, за три конфигурације боја које (А) показују статистички значајну разлику и (Б) не показују статистичку разлику. Испуњене тачке представљају конфигурације боја позадине, а кругови представљају <i>overlay</i> конфигурације боја. Слика преузета из [17] и прилагођена.	42
Слика 10. Обележје 1—детекција СП-а и Обележје 2— детекција БВП-а за испитаника са дислексијом, са линијама погледа које одговарају догађајима окидача обојеним црвеном бојом.. Слика је преузета из [19] и прилагођена.	45
Слика 11. Обележје 1—детекција СП-а и Обележје 2— детекција БВП-а за контролног испитаника, са линијама погледа које одговарају догађајима окидача обојеним црвеном бојом. Слика је преузета из [19] и прилагођена.	46
Слика 12. <i>Boxplot</i> прикази Обележја 1 за максимално раздвојене групе (контролни испитаници оцењени својим најбољим, а испитаници са дислексијом најгорим конфигурацијама) и приближене групе (контролни испитаници оцењени својим најгорим, а испитаници са дислексијом најбољим конфигурацијама). Слика је преузета из [19] и прилагођена.	50

Слика 13. <i>Boxplot</i> прикази Обележја 2 за максимално раздвојене групе (контролни испитаници оцењени својим најбољим, а испитаници са дислексијом најгорим конфигурацијама) и приближене групе (контролни испитаници оцењени својим најгорим, а испитаници са дислексијом најбољим конфигурацијама). Слика је преузета из [19] и прилагођена.	50
Слика 14. Илустрација архитектура конволуционе неуралне мреже за класификацију и конволуционог аутоенкодера. Плавом бојом су означени примери локација конволуционих кернела док црвена боја означава прелазак излаза кернела у следећи слој неуралне мреже.	54
Слика 15. Блок дијаграм алгоритма за примену конволуционе неуралне мреже за класификацију испитаника на основу координата тачке фокуса. Слика је преузета из [20] и прилагођена.	56
Слика 16. Дводимензионални прикази очних покрета испитаника са назначеним бржим и споријим очним покретима. Слика је преузета из [20] и прилагођена.	57
Слика 17. Модификована архитектура <i>VGG16</i> неуралне мреже. Слика је преузета из [20] и прилагођена.	57
Слика 18. Приказ обрасца погледа за две линије текста. База 1 лева колона, База 2 десна колона, испитаници са дислексијом горњи ред, контролни испитаници доњи ред. Слика је преузета из [18] и прилагођена.	62
Слика 19. Алгоритам обраде података за детекцију дислексије. Слика је преузета из [18] и прилагођена.	63
Слика 20. Архитектура конволуционог аутоенкодера. Слика је преузета из [18] и прилагођена.	65
Слика 21. Екстракција обележја на основу грешака у реконструкцији слике, представљена за контролног испитаника и испитаника са дислексијом. Слика је преузета из [18] и прилагођена.	66
Слика 22. Издвојена обележја за један сценарио евалуације, приказана за контролну групу и групу са дислексијом из Базе 1 и Базе 2. Слика преузета из [18] и прилагођена.	67
Слика 23. Преглед метрика класификације за најбоље добијене резултате на Бази 1 и Бази 2 у смислу ВП и сценарија обучавања аутоенкодера, за све посматране алгоритме машинског учења. Слика преузета из [18] и прилагођена.	69
Слика А1. Пример слајдова коришћених у експерименту 1/2.	75
Слика А2 Пример слајдова коришћених у експерименту 2/2.	76
Слика Б1. Приказ очних покрета контролног испитаника 1.	77
Слика Б2. Приказ очних покрета контролног испитаника 2.	77

Слика Б3. Приказ очних покрета контролног испитаника 3.....	77
Слика Б4. Приказ очних покрета контролног испитаника 4.....	78
Слика Б5. Приказ очних покрета контролног испитаника 5.....	78
Слика Б6. Приказ очних покрета контролног испитаника 6.....	78
Слика Б7. Приказ очних покрета контролног испитаника 7.....	79
Слика Б8. Приказ очних покрета контролног испитаника 8.....	79
Слика Б9. Приказ очних покрета контролног испитаника 9.....	79
Слика Б10. Приказ очних покрета контролног испитаника 10.....	80
Слика Б11. Приказ очних покрета контролног испитаника 11.....	80
Слика Б12. Приказ очних покрета контролног испитаника 12.....	80
Слика Б13. Приказ очних покрета контролног испитаника 13.....	81
Слика Б14. Приказ очних покрета контролног испитаника 14.....	81
Слика Б15. Приказ очних покрета контролног испитаника 15.....	81
Слика Б16. Приказ очних покрета испитаника са дислексијом 1.....	82
Слика Б17. Приказ очних покрета испитаника са дислексијом 2.....	82
Слика Б18. Приказ очних покрета испитаника са дислексијом 3.....	82
Слика Б19. Приказ очних покрета испитаника са дислексијом 4.....	83
Слика Б20. Приказ очних покрета испитаника са дислексијом 5.....	83
Слика Б21. Приказ очних покрета испитаника са дислексијом 6.....	83
Слика Б22. Приказ очних покрета испитаника са дислексијом 7.....	84
Слика Б23. Приказ очних покрета испитаника са дислексијом 8.....	84
Слика Б24. Приказ очних покрета испитаника са дислексијом 9.....	84
Слика Б25. Приказ очних покрета испитаника са дислексијом 10.....	85
Слика Б26. Приказ очних покрета испитаника са дислексијом 11.....	85
Слика Б27. Приказ очних покрета испитаника са дислексијом 12.....	85
Слика Б28. Приказ очних покрета испитаника са дислексијом 13.....	86
Слика Б29. Приказ очних покрета испитаника са дислексијом 14.....	86
Слика Б30. Приказ очних покрета испитаника са дислексијом 15.....	86

Списак табела

Табела 1. Региони мозга који су издвојени као значајни у релевантној литератури.	7
Табела 2. Преглед инструментације за праћење покрета очију у студијама дислексије.	13
Табела 3. Преглед обележја из литературе изведених из фиксација.	15
Табела 4. Преглед обележја из литературе изведених из сакада.	16
Табела 5. Преглед обележја изведених из очних покрета која нису директно изведена само из фиксација/сакада.	17
Табела 6. Преглед основних информација о студијама које користе праћење покрета очију за истраживање дислексије.	24
Табела 7. Преглед опција за улазне параметре у алгоритме машинског учења.	36
Табела 8. Метрике за евалуацију класификације на основу различити група метрика (резултати развијених обележја су приказани <i>bold</i> текстом).	38
Табела 9. Просечна тачност добијена на скупу за тестирање за појединачна обележја.	39
Табела 10. Метрике евалуације на тест скупу за свако обележје и за све алгоритме машинског учења.	48
Табела 11. Резултати класификације на тест скупу, на нивоу инстанце, за све разматране конфигурације неуралне мреже.	59
Табела 12. Резултати класификације на тест скупу, на нивоу испитаника, за све разматране конфигурације неуралне мреже.	59
Табела 13. Резултати евалуације на Бази 2 (обучавање на Бази 1).	68
Табела 14. Резултати евалуације на Бази 1 (обучавање на Бази 2).	68
Табела Г1. <i>Sensitivity</i> параметар за појединачна обележја као улазе у алгоритме машинског учења.	89
Табела Г2. <i>Specificity</i> параметар за појединачна обележја као улазе у алгоритме машинског учења.	89
Табела Г3. <i>F1 score</i> параметар за појединачна обележја као улазе у алгоритме машинског учења.	90
Табела Г4. <i>AUROC</i> параметар за појединачна обележја као улазе у алгоритме машинског учења.	91

Списак скраћеница

TOWRE-2

Test of Word Reading Efficiency-2

WIAT-III

Wechsler Individual Achievement Test—Third Edition

GORT-5

Gray Oral Reading Test

фМР

функционална магнетна резонанзца

ЕЕГ

електроенцефалографија

SVM

support vector machine

KNN

k nearest neighbours

RF

random forest

LR

logistic regression

ВСФ

варијабилност самопресека фиксација

СФДФ

средња фрактална димензија фиксација

ВИИ

варијабилност интерсакадних интервала

СП

самопресек

БВП

број вертикалних промена

AB

ada boost

Предговор

Реализација овог рада је извршена у оквиру Лабораторије за БиоМедицинско Инжењерство и Технологије (БМИТ) Електротехничког факултета Универзитета у Београду, а у сарадњи са Лабораторијом за неурокогницију и примењену когницију Филозофског факултета Универзитета у Београду и Лабораторијом за еЗдравство и биомедицинско инжењерство Иновационог центра Електротехничког факултета у Београду. У оквиру истраживања је коришћена база података прикупљена у оквиру постојеће студије, публиковане у [1].

Мотивација

Заступљеност неуроразвојних поремећаја који резултују потешкоћама у идентификовању речи, правопису и разумевању прочитаног се процењује да је 20% у општој популацији (17.5% у школском узрасту), док 5–7% популације има теже облике оваквих потешкоћа и дијагнозу дислексије [2]. Сходно заступљености и негативним утицајима које дислексија може имати на квалитет живота укључујући едукативне, социјалне и емоционалне аспекте [3,4], она је предмет мултидисциплинарних истраживања, како за успостављање дијагнозе, тако и за евалуацију, мониторинг и асистенцију [5,6].

У оквиру истраживања која се баве дислексијом из перспективе биомедицинског инжењерства, примењују се различити приступи засновани на методама мерења физиолошких показатеља, укључујући површинска мерења можданих активности (електроенцефалографија) [7], методе медицинског сликања можданих структура и функција магнетном резонанцом [8] и праћење покрета очију [9]. Коришћење оваквих приступа омогућава боље разумевање самих физиолошких механизма, квантификацију дислексичних тенденција и развој алата за објективну процену нивоа поремећаја и праћење ефеката третмана. С обзиром на то да је дислексија дефинисана као поремећај везан за читање, уобичајени приступ у биомедицинском истраживању овог феномена се фокусира на директну анализу самог визуелног процеса током читања, тј. на анализу покрета очију. Прва истраживања дислексичних тенденција на бази анализе покрета очију су спроведена још 90-их година 20. века, а резултати су показали да постоје разлике између образаца очних покрета код деце са и без дислексије [10]. Развој модерних технологија је омогућио примену напредних алгоритама обраде сигнала у процесу квантификације образаца очних покрета, као и коришћење алгоритама машинског учења у развоју алата за аутоматско идентификовање дислексичних образаца. Очни покрети током читања се састоје из низа фиксација (задржавање погледа на тачкама унутар текста) и сакада (скоковитим покретима између тачака фиксација). Низ спроведених студија у домену класификације образаца очних покрета на дислексичне vs неуротипичне се фокусирао на проналажење репрезентативних обележја за опис понашања фиксација и сакада током читања, уз примену различитих алгоритама машинског учења за класификацију [9,11–15]. Услови истраживања у поменутим студијама су били врло разнолики, и у погледу матерњег језика на коме су деца читала (шпански, шведски, грчки, фински и француски), и у погледу експерименталних услова (протокола снимања, просторне и временске резолуције уређаја за снимање очних покрета). Рапортиране тачности класификације на бази обележја која описују понашање фиксација/сакада током читања су биле у опсегу 80,18% до 96%. Развој дубоких неуралних

мрежа је иницирао и примену другачијег, холистичког приступа [16] у коме се избегава сегментација очних покрета на фиксације и сакаде, већ се на минимално процесираних сигнала покрета очију примењују дубоке конволуционе мреже. Тачност класификације дислексичних образаца читања на шведском језику је достигла вредност од 96.6.% применом холистичког приступа.

Имајући у виду број студија и значај успостављања дијагнозе дислексије, главна мотивација ове дисертације је развијање различитих алата који могу служити за објективно успостављање дијагнозе дислексије за особе чији је матерњи језик српски. Иако постоје студије које су се бавиле статистичком анализом покрета очију код деце чији је матерњи језик српски [1], не постоје студије које се баве успостављањем дијагнозе дислексије за српски језик применом метода машинског учења, а на основу биомедицинских мерења.

Циљ истраживања и полазне хипотезе

Циљ истраживања дисертације је развој интелигентних система за класификацију образаца очних покрета испитаника са дислексијом и неуротипичних испитаника чији је матерњи језик српски. Истраживања обухватају оба приступа анализе покрета очију, и приступ базиран на проналажењу репрезентативне дескрипције фиксација/сакада и холистички приступ. Осим недвосмислене националне важности овог истраживања, посебан значај овог истраживања у техничком смислу лежи у превазилажењу изазова који прате отежану детекцију дислексије у језицима плитке ортографије где је српски језик репрезент „идеалне“ ортографије (бијективног пресликавања између графема и фонема).

Полазне хипотезе истраживања приказаног у дисертацији су:

- Хипотеза 1. Обрасци покрета очију током читања на српском језику се разликују у просторном и временском домену између деце са дислексијом и неуротипичне деце тако да је могуће обезбедити аутоматску идентификацију дислексичних образаца;
- Хипотеза 2. У реалном времену, помоћу интерпретабилних и робусних обележја је могуће идентификовати дислексичне обрасце несегментираних очних покрета током читања на српском језику;
- Хипотеза 3. Могуће је развити алат за детекцију дислексичних тенденција на основу несегментираних сигнала очних покрета који се може применити у различитим експерименталним условима

Научни доприноси

У оквиру предложене докторске дисертације постигнути су следећи доприноси:

- увођење нових просторних и временских обележја очних покрета ефикасних у детекцији дислексичних образаца током читања на српском језику помоћу алгоритама машинског учења;
- увођење робусних и интерпретабилних обележја очних покрета погодних за детекцију дислексичних тенденција у реалном времену током читања на српском језику помоћу алгоритама машинског учења;

- анализа утицаја боје позадине текста за читање на сепарабилност дислексичних и недислексичних образаца очних покрета;
- предлог новог интелигентног система за детекцију дислексичних тенденција на основу несегментираних сигнала покрета очију при читању применом конволуционих неуралних мрежа;
- предлог новог интелигентног система за детекцију дислексичних тенденција заснованог на *encoding*-у сигнала покрета очију при читању, робусног у погледу експерименталних услова.

Научни радови из којих је проистекла докторска дисертација

Резултати истраживања описаног у докторској дисертацији су објављени у радовима у међународним часописима (3 публикације) и зборницима међународних конференција (1 публикација).

Радови у међународним часописима

1. **I. Vajs**, V. Ković, T. Papić, A. M. Savić, and M. M. Janković, “Spatiotemporal Eye-Tracking Feature Set for Improved Recognition of Dyslexic Reading Patterns in Children,” *Sensors*, vol. 22, no. 13, 2022. ISSN 1424-8220, Impact factor 3.847, doi: <https://doi.org/10.3390/s22134900> (M21) - референца [17]
2. **I. A. Vajs**, G. S. Kvašček, T. M. Papić, and M. M. Janković, “Eye-Tracking Image Encoding: Autoencoders for the Crossing of Language Boundaries in Developmental Dyslexia Detection,” *IEEE Access*, vol. 11, pp. 3024–3033, 2023. ISSN 2169-3536, Impact factor: 3.476, doi: <https://doi.org/10.1109/ACCESS.2023.3234438> (M22) - референца [18]
3. **I. Vajs**, T. Papić, V. Ković, A. M. Savić, M. M. Janković, “Accessible Dyslexia Detection with Real-Time Reading Feedback through Robust Interpretable Eye-Tracking Features,” *Brain Sciences*, vol. 13, no. 3, p. 405, 2023. ISSN 2076-3425, Impact factor: 3.333, doi: <https://doi.org/10.3390/brainsci13030405> (M23) - референца [19]

Радови у зборницима са међународних научних скупова

1. **I. Vajs**, V. Ković, T. Papić, A. M. Savić, and M. M. Janković, “Dyslexia detection in children using eye tracking data based on VGG16 network,” *Proceedings of 30th European Signal Processing Conference (EUSIPCO 2022)*, pp. 1601 - 1605, 29. Aug-2. Sep, Belgrade, 2022. (M33) - референца [20]

Структура докторске дисертације

Представљена докторска дисертација има 9 главних целина и 4 прилога.

Прва секција представља увод, у коме постоји 2 потпоглавља. У првој секцији увода, секцији 1.1, је приказан кратак осврт на различите дефиниције дислексије и њену заступљеност у општој популацији. Затим се, у секцији 1.2 даје преглед метода за стандардно успостављања дијагнозе дислексије укључујући примере коришћених тестова за евалуацију различитих језичких способности.

У другој секцији се описују биометријски приступи за успостављање дијагнозе дислексије. У секцији 2.1. описују се методе магнетне резонанце и функционалне магнетне резонанце које се користе у студијама дислексије. Секција садржи кратак опис инструментације која се користи, као и метода за обраду података. У секцији 2.2 се описује метода електроенцефалографије и њена примена у успостављању дијагнозе дислексије, пратећи инструментацију у постојећим студијама и коришћене методе обраде података. У секцији 2.3. је дат детаљан преглед инструмената и обележја која су коришћена у различитим студијама дислексије везаним за праћење покрета очију. Дат је преглед обележја по категоријама као и кратка дискусија о заступљености обележја у литератури.

У секцији 3 даје се преглед студија које користе статистичку анализу за поређење групе са дислексијом и контролне групе. Ова секција даје свеобухватан увид у спроведене студије, са кратким описом студије и наведеним најважнијим закључцима.

Секција 4 даје преглед студија у којима се врши препознавање дислексичних образаца применом машинског учења, уз кратак опис студија и постигнуте тачности класификације.

Секција 5 даје кратак преглед метода за терапију дислексије, као и могућности асистивних технологија.

Секција 6 обухвата опис базе података која је коришћена у раду, укључујући дизајн стимулуса, експерименталну поставку, број испитаника и остале детаље релевантне за студију.

Секција 7 представља поглавље које се фокусира на карактеризацију покрета очију помоћу обележја и коришћење алгоритама машинског учења за класификацију испитаника у групу са дислексијом или у неуротипичну групу. На почетку поглавља у секцији 7.1 дат је кратак увод у поглавље са мотивацијом. Затим је у секцији 7.2 приказан развијени начин приказа очних покрета, који је коришћен за анализу и испитивање постојећих података. Анализа визуелизације је резултовала развојем обележја заснованих на просторним и временским карактеристикама сакада и фиксација, која су описана у секцији 7.3. Ова секција садржи опис методе, представљене резултате са дискусијом и изведене закључке. Затим се у секцији 7.4 представљају обележја која не захтевају поделу секвенце погледа на фиксације и сакада, и која су робусна спрам фреквенције одабирања података. Секција 7.4 садржи комплетан опис методе, постигнутих резултата и коначни закључак. Анализа утицаја конфигурације боја на којима је приказан текст је такође приказана у секцијама 7.3 и 7.4 користећи одговарајућа описана обележја.

Секција 8 представља поглавље које описује класификацију очних покрета на дислексичне и неуротипичне без коришћења обележја, употребом конволуционих неуралних мрежа. На почетку осмог поглавља, у секцији 8.1 дат је кратак увод и опис литературе у којој су коришћене конволуционе неуралне мреже за детекцију дислексије. Такође је дат опис конволуционих неуралних мрежа, њихове примене, и једног конкретног типа архитектуре неуралне мреже – конволуционог аутоенкодера, који је коришћен у даљим секцијама овог поглавља. У секцији 8.2 описани су метода, резултати, дискусија и закључак класификације очних покрета испитаника у дислексичне и неуротипичне применом конволуционе неуралне мреже. Описан је принцип *encoding*-а података (конверзија секвенци координата у слике) и архитектура неуралне мреже, као и постигнути резултати и њихове импликације. У секцији 8.3 је приказан алгоритам обраде који се заснива на конволуционом аутоенкодеру, а

који користи више различитих елемената како би омогући класификацију дислексичних очних покрета која је неосетљива на различите експерименталне услове. У секцији 8.3 је поред базе испитаника чији је матерњи језик српски (која је коришћена у остатку дисертације) коришћена још једна отворена база података коју чине испитаници чији је матерњи језик шведски. Посматране базе података имају веома различите експерименталне поставке, а описани алгоритам квантификује просторну сложеност покрета очију тако да се може обучити на једној бази а применити на другој.

На крају дисертације је дат закључак, са наведеним хипотезама и научним доприносима дисертације (секција 9.1) и наведеним смерницама за даљи рад (секција 9.2).

У Прилогу А су приказани примери слајдова који су коришћени као стимулуси за базу података коришћену у дисертацији.

У Прилогу Б је дат пример приказа очних покрета за све испитанике током читања на белој боји, помоћу методе визуелизације предложене у дисертацији.

У Прилогу В се налази кратак преглед коришћених алгоритама машинског учења, њихових функционалности и хиперпараметара.

У Прилогу Г се налазе додатне метрике за евалуацију класификатора обученим на појединачним обележјима из секције 7.3.2.

1 Увод


1.1 Дефиниција и заступљеност дислексије

Дислексија се у савременим истраживањима наводи као неуробиолошки поремећај који утиче на флуентност и тачност читања, као и разумевање прочитаног садржаја [21]. Тренутно не постоји опште прихваћена формална дефиниција овог поремећаја, али многе институције и удружења дају различите дефиниције које описују дислексију и њене манифестације.

Према Међународном удружењу за дислексију (*The International Dyslexia Association*) основна карактеристика дислексије је сметња у тачном и/или течном препознавању речи која је изазвана поремећајима у фонолошкој обради [22]. Ове потешкоће настају неvezано од интелектуалних или сензорних поремећаја, а нису у складу са очекиваним резултатима спрам когнитивних капацитета и степена образовања. Европско удружење за дислексију (*European Dyslexia Association*) као главне карактеристике дислексије наводи сметње у стицању способности читања, писања и спеловања [23]. Потешкоће у фонолошкој обради се наводе као главни узрок, конкретно поремећаји вербалне радне меморије, брзог именовања и способности сегментације. Такође, истиче се да интелигенција, лични труд и социјално-економски статус немају везе са појавом дислексије. Америчко удружење психијатара (*American Psychiatric Association*) дислексију дефинише као неуролошки поремећај у учењу који се манифестује тешким проблемима са читањем, писањем и спеловањем речи [24]. Као у претходној дефиницији, и у овој се сматра да дислексија нема везе са интелигенцијом, сензорним поремећајима или недостатком мотивације. Америчко удружење психолога такође наводи две начелне групе дислексије, дислексију везану за визуелну обраду речи која се карактерише проблемима са анализом писаних речи и централну дислексију која се карактерише проблемима у вишим процесима читања попут изговарања прочитане речи и разумевања прочитаног.

Процена заступљености дислексије у општој популацији је тема многих истраживања и може се наћи широк распон процена, са доњом границом испод 5% па све до горње границе од 20% [25]. Прецизна процена заступљености дислексије представља изазов, јер на спроведена истраживања велики утицај могу имати сама дефиниција дислексије као и различити приступи успостављања дијагнозе [26]. Према Европском удружењу за дислексију, процењује се да између 9% и 12% европске популације има дислексију и наводи се да се дислексија често јавља заједно са другим поремећајима. Процене Европског удружења за дислексију су да између 20% и 55% особа са неким језичким поремећајем има дислексију, а 8% до 18% особа са дислексијом има и поремећај пажње/хиперактивности. Успостављање јасне дијагнозе дислексије подразумева јасну диференцијалну дијагностику, а само издвајање дислексије у односу на наведена два поремећаја представља значајну препреку за процену заступљености дислексије, поготово узимајући у обзир различите манифестације које дислексија има за различита европска говорна подручја.

Посматрајући трендове у релевантној литератури, може се установити да са развојем модерних технологија расте и број научних публикација које се баве дислексијом (Слика 1.). Било да се ради о истраживањима која се баве фундаменталним разумевањем појава дислексије, биометријским приступима, језичким способностима или неким другим аспектом, растући тренд броја публикација указује на значај истраживања и разумевања дислексије.



Слика 1. Преглед броја публикација које се баве дислексијом по годинама из два различита репозиторијума (*Scopus* и *PubMed*, септембар 2023).

1.2 Дијагноза дислексије

Рана дијагноза дислексије је од посебног значаја због негативног утицаја који дислексија може имати на академске резултате и ментално здравље [27,28]. Постоји велики број стандардизованих тестова који се користе током процеса успостављања дијагнозе, а који се баве евалуацијом различитих језичких способности.

Тестови за процену фонолошке свести се користе за анализирање способности особе да препозна и модификује одређене делове изговорених реченица или речи. Иако ови тестови не мере способности читања, сматрају се веома битним за успостављање дијагнозе дислексије, јер се фонолошке способности сматрају основом за добро читање. Овај тип тестова се такође може применити у раном узрасту, када способност читања још увек није развијена, а у циљу раног успостављања дијагнозе дислексије. У оквиру тестова може постојати више различитих скала које прате могућности римовања, синтезе, сегментације, брисања фонеме и замене фонеме. Примери тестова који се користе у сврху процене фонолошке свести су *Phonological Awareness* [29], *Comprehensive Test of Phonological Processes* [30], *NEPSY-II Phonological Processing subtest* [31], *ELLA – Emerging Literacy & Language Assessment* [32].

За успостављање дијагнозе дислексије од интереса могу бити и тестови који се фокусирају на декодирање речи. Ови тестови примарно испитују способности испитаника да врши графемско-фонемске конверзије тј. да на основу писаних слова правилно изговори дату реч. Ови тестови су важни зато што испитаници могу имати привидно добар степен читања који је резултат учења речи напамет, а не адекватних вештина конверзије графема у фонеме. Ови тестови се састоје од читања појединачних речи и псеудоречи наглас, где је претпоставка да испитаник мора применити декодовање како би адекватно изговорио псеудореч, чак и у случају да реч „зна напамет“. Примери тестова који се користе за процену способности декодовања су *Test of Word Reading Efficiency-2 (TOWRE-2)* [33] и *Pseudoword Decoding subtests of the Wechsler Individual Achievement Test–Third Edition (WIAT-III)*[34].

Као директан увид у сам процес читања, користе се тестови за процену флуентности читања и разумевања прочитаног. Ови тестови мере способност испитаника да наглас прочита параграф текста и да покаже разумевање садржаја прочитаног текста. За разлику од тестова декодовања, ови тестови процењују способност читања речи у контексту и на тај начин дају приказ о способности читања у „реалним условима“. Примери тестова који се користе су *Gray Oral Reading Test (GORT-5)* [35], *Reading Comprehension WIAT-III* [34] и *TOWRE-2* [33].

Праћење способности брзог именовања се такође користи у сврхе успостављања дијагнозе дислексије. У овим тестовима се прати колико брзо испитаник може да именује слова, бројеве, боје и предмете који су му током испитивања приказани. Добра способност брзог именовања значи да испитаник добро и брзо барата фонолошким информацијама, што је веома значајно за дијагнозу дислексије, пошто је ова способност често нарушена или успорена код људи са дислексијом. Примери тестова који се користе су *Rapid Automatized Naming Test* [36] и *Speeded Naming subtest of NEPSY-II* [31].

У истраживањима дислексије на српском језику користе се различити тестови из наведених категорија, неки који су посебно развијени за српски језик, а неки који представљају адаптације постојећих тестова за енглески језик [37,38]. У истраживању дислексије на српском језику посебан фактор представља дубина ортографије. Ортографија српског језика је веома плитка, за разлику од ортографије језика као што је енглески где су правила графемско-фонемске и фонемско-графемске конверзије много комплекснија. Ово чини српски језик једноставнијим за читање и писање у односу на енглески, али такође може представљати изазов у контексту успостављања дијагнозе дислексије помоћу тестова језичких способности [39].

Развој нових технологија и дигитализација су утицали на многе научне области, укључујући и истраживачки рад везан за дислексију. Дигитални тестови за успостављање дијагнозе дислексије представљају један од значајнијих искорака, како у смислу дигитализације конвенционалних дијагностичких метода, тако и у увођењу нових метода које се заснивају на биометријским мерењима.

Online тестови за евалуацију дислексије су широко распрострањени и могу дати елементарне смернице за даље анализе и указати на потенцијално постојање проблема. Ови тестови се најчешће заснивају на упитницима који захтевају бинарне одговоре или одговоре на одређеној скали и из тог разлога подлежу грубој процени и субјективности [40]. Постоје и *online* тестови који садрже елементе стандардних језичких евалуација и тиме укључују објективне и мерљиве резултате, попут вежби радне меморије, читања речи и псеудоречи наглас и разумевања прочитаног текста [41,42].

У циљу успостављања објективне дијагнозе и праћења њених манифестација, различите студије се фокусирају на биометријски приступ, тј. на посматрање структурних или функционалних промена помоћу медицинске слике (магнетна резонанца, функционална магнетна резонанца – секција 2.1) или на праћење реакција организма помоћу одговарајућих физиолошких приступа (електроенцефалографија – секција 2.2; праћење покрета очију – секција 2.3). Овакви биометријски приступи омогућавају објективност и квантитативни приказ, као и увид у одређене механизме функционисања особа са дислексијом.

2 Биометријски приступи у дијагнози дислексије

2.1 Примена медицинског сликања у дијагнози дислексије

Инструментација

Како се дислексија води као неуробиолошки поремећај, од посебног интереса је праћење можданих активности особа са дислексијом током различитих задатака. Једна од најчешће коришћених метода у студијама проучавања дислексије је функционална магнетна резонанца (фМР) [43].

фМР је неинвазивна метода помоћу које се прате региони мозга који су активни током спровођења експеримента. фМР се заснива на основним принципима магнетне резонанце, која користи магнетно поље и природу протона како би се забележиле информације о различитим ткивима. Јако магнетно поље које производи магнетна резонанца утиче на протоне у телу тако да се поравнавају са смером деловања тог поља. Када се радиофреквентно поље пусти да пулсира кроз пацијента, протони бивају стимулирани и излазе из равнотеже, долазећи у положај који није у складу са деловањем магнетног поља. Када је радиофреквентно поље искључено, сензори у магнетној резонанци детектују енергију која се ослобађа када се протони поново поравнавају са смером магнетног поља. Време које је потребно протонима да се поравнају, као и количина ослобођене енергије, мења се у зависности од средине и хемијске природе молекула. На основу ове две физичке величине, могу се препознати различита ткива и промене на њима. фМР, за разлику од структурне магнетне резонанце, на основу мерених физичких величина не прати примарно разлику у ткивима већ разлику у реакцији хемоглобина са и без кисеоника. На овај начин је могуће пратити који региони мозга користе више кисеоника, тј. који региони мозга су активнији, а који мање активни. Снимци фМР и структурне магнетне резонанце се раде по пресецима, тј. добија се секвенца слика. Разлика је у томе што структурна магнетна резонанца даје једну секвенцу слика које описују структуру мозга, док фМР даје више секвенца слика кроз време, где свака секвенца слика описује активност мозга у датом тренутку.

фМР карактерише висока просторна резолуција (стандардно око 3-4 mm) али ограничена временска резолуција (реда величине једне секунде). У студијама које се баве анализом дислексичних тенденција, може се наћи више различитих уређаја који су коришћени за праћење мождане активности, који имају различите карактеристике. У протоколе аквизиције фМР улази велики број параметара, али ће у наставку бити издвојени само инструменти коришћени у студијама дислексије и параметри аквизиције везани за просторну резолуцију снимака као најзанчајније информације за каснију квантификацију дислексичних тенденција.

У [44] и [45] је коришћен скенер целог тела *MedSpec S300 (Bruker, Billerica, Масачусетс, Сједињене Америчке Државе)* са снагом поља од 3 Т. Прикупљен је 41 суседни аксијални пресек и дебљина пресека била је 3,5 mm. Величина воксела у равни је била 3×3 mm (216×216 mm видног поља добијеног помоћу матрица података величине 72×72 пиксела; реконструисане са допуњавањем са вредности 0 до 128×128 пиксела).

фМР са снагом поља од 1,5 Т, *Siemens Vision Plus (Siemens, Минхен, Немачка)* је коришћена у [46]. Снимци су се састојали од 25 аксијалних пресека са дебљином пресека од 5,5 mm, укључујући размак између пресека од 0,5 mm. Величина воксела у равни је била 4×4 mm са матрицом података величине 64×64 пиксела и видим пољем од 256×256 mm.

У [47] је коришћен скенер главе од 3 T *Signa™ Premier (General Electric, Бостон, Масачусетс, Сједињене Америчке Државе)*. Функционалне слике мождане активности су сакупљене помоћу величина матрице од 110×110 пиксела, дебљином пресека од 2 mm и видним пољем од 220×220 mm (ефективно дајући величину воксела у равни од 2 mm). Број пресека мозга за сваки снимак је био 66.

За прикупљање снимака функционалне магнетне резонанце, у [48], коришћен је *Siemens Prismafit (Siemens, Минхен, Немачка)* скенер са снагом од 3 T. Дебљина пресека је износила 3 mm са 0,6 mm размака и дата је само резолуција воксела у равни која је била 3×3 mm.

Поред анализа можданих активности са циљем детекције дислексичних тенденција, урађене су и студије у којима је праћена сама морфологија мозга дислексичних и неуротипичних испитаника. Ове студије су укључивале структурне снимке магнетне резонанце, који су такође прикупљени коришћењем различитих уређаја са различитим подешавањима. У наставку су неки основни наведени параметри, примарно тип уређаја и просторна резолуција снимака који су коришћени у овом типу студија.

У [49] аутори су користили *1.5-Tesla Magnetom Avanto MRI* скенер (*Siemens, Минхен, Немачка*) а величином воксела од 1×1×1 mm. У [50] је коришћен *SIGNA™ 1.5T (General Electric, Бостон, Масачусетс, Сједињене Америчке Државе)* са размаком између пресека од 2 mm за снимке у короналној равни и 1,5 mm за снимке у аксијалној равни. Димензије пиксела на сваком пресеку су биле 0,9375×0,9375 mm. У [51] коришћен је *Achieva* скенер са јачином поља од 3 T (*Philips, Амстердам, Холандија*). Величина воксела је 1×1×1 mm са 256×256 mm видног поља и 160 пресека за сваку од три равни у којој је урађена аквизиција. У неким студијама су чак коришћена два различита уређаја што је случај у [52]. У овој студији, на делу испитаника је коришћен *Vision Magnetom 1.5 T* скенер (*Siemens, Минхен, Немачка*), а на остатку испитаника је коришћен *Trio scanner 3 T (Siemens, Минхен, Немачка)*. Величина воксела за оба скенера је износила 1×1×1 mm са 256×256 mm видног поља и 173 пресека снимљених у сагиталној равни.

Као што се може уочити, постоји велики број различитих уређаја који је коришћен у студијама везаним за анализу неуралне активности/структуре код испитаника са дислексијом помоћу магнетне резонанце. У студијама се такође може пронаћи веома различит скуп вредности за параметре аквизиције који утичу на крајње добијене податке. Без обзира на разлике, све студије су имале за циљ да опишу неуралне механизме код испитаника са дислексијом, а ово је постигнуто коришћењем различитих метода за квантификацију и обраду прикупљених података.

Квантификација дислексичних тенденција

У студијама које користе фМР за праћење дислексичних тенденција испитаника, издваја се јасан образац обраде података, и издвајање јасне квантификације мождане активности. У свакој од наведених студија које користе фМР први корак обраде података представља претпроцесирање прикупљених снимака. Овај корак подразумева просторно поравнавање свих пресека,. Поравнавање пресека је неопходно пошто су блага померање главе између аквизиције снимака сваког пресека неизбежна, јер између њихове аквизиције протекне одређени временски период. Поред поравнања, врши се и корекција самих вредности мерења тј. утицај померања на снимљене вредности. У претпроцесирање потпада и примена изотропног дводимензионалног гаусовског кернела како би се усредњиле вредности суседних воксела, а на крају се примењује филтар пропусник високих фреквенција на временске секвенце вредности саког воксела како би се уклонио нискофреквентни шум и дрифт [53].

Након завршеног претпроцесирања, даља анализа снимака фМР се ради тако што се прате активности у различитим регионима мозга. Овај корак подразумева да се испрате два различита аспекта, временски и просторни. Дакле, на основу локације, сваки воксел се додељује одређеном региону мозга и на тај начин се користи за процену да ли је тај регион мозга у датом тренутку активан или не. Временски аспект, подразумева да се прати можда реакција у тачно одређеном периоду, тј. реакција на конкретан приказани стимулус. Коришћењем овог концепта, фМР студије омогућавају праћење реакције различитих делова мозга испитаника на већи број стимулуса.

У наведеним фМР студијама, конкретни резултати који се користе за поређење групе са дислексијом и контролне групе представљају регионе мозга који су активирани током одређеног задатка, а њихова активација се квантификује бројем воксела који одређеном региону припадају, а који су имали повишену активност током интеракције са стимулусом. Различите просторне резолуције снимака у овом контексту играју значајну улогу, јер могу не само дати поузданију слику за један конкретан регион мозга, већ могу потенцијално издвојити и пратити активност ситнијих структура или мањих региона мозга. Региони од интереса који се појављују као значајни у издвојеним студијама су наведени у Табели 1.

Аналогно студијама које се баве фМР методом, студије које се баве структурном магнетном резонанцом анализирају сиву мождану масу по различитим регионима мозга. Конкретно, ове студије уместо активности у одређеним можданим структурама, прате анатомске разлике које квантификују на основу детектоване запремине сиве масе. У [49] аутори су издвојили неколико региона мозга који су били значајни за анализу и разликовање неуротипичне групе и групе са дислексијом, а то су леви доњи фронтални гирус, мали мозак, десни *putamen*, и билатерални паријетални кортекс. Слично, у [51], аутори су издвојили запремину сиве масе у неколико региона мозга који су се показали релевантни: леви и десни окципитални фузиоформни гирус и лева доња паријетална лобула. У [52], аутори посматрају разлике код сваког пола засебно. Аутори издвајају сиву мождану масу из средњег и доњег темпоралног гируса и десног супрамаргиналног гируса код мушкараца, док код жена од интереса бивају десни *precuneus* и працентрална лобула као и медијални фронтални гирус. Постоје и студије које се не баве чистом анализом запремине сиве мождане масе, већ се баве њеним обликом, што је случај у [50]. У овој студији, аутори анализирају облик кортекса користећи сферичну хармоничну анализу, и ефективно покушавају да квантификују комплексност облика кортекса на основу ове анализе, и да посматрају како та комплексност корелише са дислексијом.

Посматрајући наведене методе квантификације дислексичких тенденција за наведене студије медицинске слике, може се извести неколико закључака. Како се дислексија наводи као неуробиолошки поремећај, анализа неуралног аспекта дислексије представља један од логичних приступа. Методе медицинске слике нуде велику просторну резолуцију, и могућности праћења различитих мањих можданих региона. У наведеним студијама које користе фМР методу, као најзначајнији региони се издваја леви средњи фронтални гирус, мада постоји велики број различитих региона мозга у којима се показују различите мождане активности. Важно је напоменути да фМР подразумева реакцију на одређени стимулус, тако да се спрам различитог дизајна експеримента може очекивати разлика у другачијим регионима мозга. Са друге стране, разлике у морфологији које се посматрају у студијама структурне магнетне резонанце немају везе са одређеном реакцијом, већ са распоредом сиве мождане масе, који се не мења током снимања. Резултати у овим студијама који указују да постоје и морфолошке разлике између испитаника са дислексијом и неуротипичних испитаника, указују на интересантан концепт да разлика не постоји само у неуралним механизмима већ и у самим структурама.

Табела 1. Региони мозга који су издвојени као значајни у релевантној литератури.

Регион мозга	Референца
Леви средњи фронтални гирус	[44] [46] [47] [48]
Леви доњи темпорални гирус	[44] [47] [48]
Лева горња паријетална лобула	[44] [45] [46]
Десни <i>precuneus</i>	[44] [45] [48]
Леви горњи темпорални гирус	[44] [47] [48]
Леви фузиоформни гирус	[44] [46] [47]
Десна горња париетална лобула	[45] [46] [48]
Лева доња паријетална лобула	[46] [47] [48]
Леви супрамаргинални гирус	[44] [47]
Леви <i>precuneus</i>	[44] [45]
Десни средњи темпорални кортекс	[44] [46]
Леви доњи фронтални гирус	[44] [47]
Десна доња париетална лобула	[46] [48]
Леви примарни моторни кортекс	[44] [47]
Леви језички гирус	[46] [48]
Леви горњи фронтални гирус	[46] [48]
<i>Left pre-supplementary motor area</i>	[47]
<i>Bilateral pre-supplementary motor area</i>	[45]
Десни доњи темпорални кортекс	[44]
<i>Left supplementary motor area</i>	[47]
Десна инсула	[45]
Десни средњи фронтални гирус	[46]
Леви доњи окципитални гирус	[44]
Леви мали мозак	[46]
Десни мали мозак	[46]
Десни језички гирус	[48]
<i>Cingulate</i> гирус	[46]
Леви вентрални премоторни кортекс	[47]
Леви задњи доњи темпорални кортекс	[47]
Десни предњи мали мозак	[47]
Десни задњи мали мозак	[47]
Леви таламус	[47]
Леви <i>putamen</i>	[47]
Леви угаони гирус	[48]
Леви средњи окципитални гирус	[48]
Леви <i>cuneus</i>	[48]
Десни средњи окципитални гирус	[48]
Лева <i>insula</i>	[48]
Леви трансферзални темпорални гирус	[48]

Један аспект неуралних механизма који студије медицинске слике не могу пратити на најбољи начин је динамика неуралне активности. Морфологија мозга је сама по себи непроменљива током снимања, а фМР која прати неуралне активности то ради са веома ограниченом временском резолуцијом (реда величине једне секунде). Праћење временског аспекта неуралне реакције је


могуће учинити коришћењем много веће временске резолуције, али са смањеном просторном селективношћу мерења, и за ово се користи метода електроенцефалографије (ЕЕГ).

2.2 Примена електроенцефалографије у дијагнози дислексије

Инструментација

Електроенцефалографија (ЕЕГ) је метода која се заснива на мерењу електричне активности неуралних структура на површини коже [54]. Ова метода, за разлику од фМР, не мери метаболички резултат неуралне активности, већ саму неуралну активност. ЕЕГ подразумева поставку одређеног броја електрода на површину коже главе и мерење електричне активности која се појављује као резултат сумирања акционих потенцијала који настају у ћелијама мозга. ЕЕГ сигнали имају релативно малу амплитуду (реда величине од 10 до 100 μV) зато што електрична активност неурона пролази кроз различите структуре (цереброспиналну течност, лобању, слојеве коже, итд.) пре него што постане видљива електродама које су постављене на површину коже главе. Из овог разлога, омогућавање што квалитетнијег контакта електроде са кожом главе је од великог значаја, узимајући у обзир да треба што више умањити шум који потиче од контакта кожа-електрода. Приликом аквизиције ЕЕГ сигнала, могуће је користити различит број електрода. Просторна резолуција ЕЕГ мерења је сама по себи смањена у односу на резолуцију фМР, из разлога што ЕЕГ мери неуралну активност на површини коже главе, тако да је мерење активности можданих структура које су унутар мозга ефективно немогуће. Са друге стране, праћење активности у различитим регионима на површини мозга зависи од броја и позиције електрода које се користе. Детаљан приказ примера поставке електрода и њихових ознака се налази на Слици 2.

ЕЕГ електроде се спрам позиције могу поделити у неколико категорија: пре-фронталне (Fp), фронталне (F), темпоралне (T), паријеталне (P), окципиталне (O) и централне (C) електроде. Електроде са наставком *z* (енг. *zero*) представљају електроде постављене на средину лобање и најчешће се користе као референтне електроде за мерења. Постоје и ознаке за електроде које се налазе између одређених регија, попут AF за електроде између фронталних и пре-фронталних, FC између фронталних и централних, FT између фронталних и темпоралних, итд. Што је већи број електрода то је могуће имати већу просторну резолуцију у оквиру региона где су електроде постављене. Такође, различити системи имају различите фреквенције одабирања ЕЕГ сигнала, тако да од система зависи и колико прецизно се могу пратити одређене реакције у времену. Све информације од значаја, као и модели самих ЕЕГ система су наведени у наставку за издвојене студије које користе ЕЕГ за анализу дислексије.



Слика 2. Приказ локација ЕЕГ електрода у складу са опште прихваћеним 10-20 стандардом [55]. Приказ реализован помоћу *mne* библиотеке [56].

У [57] коришћен је *Biosemi ActiveTwo system* (*Biosemi*, Амстердам, Холандија) са 64 електроде. Групе електрода које су посматране су Fp, AF, F, FC, C, CP, FT, O, PO и P електроде. Аквиизиција сигнала је урађена са фреквенцијом одабирања од 1024 Hz. У [58], аутори наводе само коришћење софтвера *BrainVision Recorder* (*Brain Products GmbH, Gilching*, Немачка) и коришћење ЕЕГ система са 32 електроде и фреквенцију одабирања од 1000 Hz. У [59], аутори наводе коришћење 38 електрода и *NeuroScan* (*Compumedics Neuroscan*, Викторија, Аустралија) софтвера за аквизицију. Групе електрода које су посматране су Fp, F, P, M, T и O, а фреквенција одабирања је постављена на 500 Hz. У [60] аутори користе *Biosemi ActiveTwo system* (*Biosemi*, Амстердам, Холандија) за аквизицију са фреквенцијом одабирања од 1024 Hz. Наводи се да се користе 64 електроде, али се за даљу анализу користи само 9: O1, O2, P7, P8, C3, Cz, C4, F5, F6. За студију спроведену у [61] користи се развијен систем који се састоји од 40 електрода. Фреквенција одабирања је износила 250 Hz, а групе електрода које су посматране су F, C, T, P, O, AF, FT, FC, CP и TP.

Посматрајући кратак преглед инструмената који су коришћени у издвојеним студијама дислексије, може се уочити да сва наведена инструментација има значајно већу временску резолуцију у односу на методе медицинске слике. Још једна предност ЕЕГ-а у односу на медицинску слику, је што су ЕЕГ системи неупоредиво повољнији по питању цене и што су преносиви. Поставка ЕЕГ система захтева одређено време, јер је неопходно обезбедити адекватан контакт између електрода и коже главе, али се ЕЕГ системи могу користити практично било где, док методе медицинске слике захтевају коришћење гломазних апарата. Још једна ставка која се разликује у поставци наведених студија је број коришћених електрода. Уопштено посматрано,

већи број електрода даје више детаља, и генерално говорећи даје бољи снимак, али захтева дужу поставку, и овакви системи обично имају већу цену. За различите типове анализе података, могу бити потребне информације из конкретних региона мозга, тако да велики број електрода може бити редундантан. Из овог разлога је важно адекватно изабрати ЕЕГ инструмент, узимајући у обзир циљ студије.

У контексту посматрања различитих електрода, важно је узети у обзир још један фактор, а то је дизајн експеримента. ЕЕГ не анализира морфолошке структуре, већ реакцију на стимулусе, или евентуално ЕЕГ у стању мировања. Праћење ЕЕГ-а у стању мировања може донекле бити аналогија студијама које се баве морфологијом мозга, јер иако је у питању праћење неуралне активности, не посматра се реакција на конкретан стимулус, већ неурална динамика у одсуству стимулуса. Са друге стране, могуће је користити ЕЕГ и за праћење неуралне активности услед реакције на неки конкретан стимулус или задатак. Приликом различитих задатака или активности, може се очекивати да могу бити од интереса различити региони мозга који су активни током тог задатка. Самим тим, за различите дизајне експеримената, за исти тип групе која се посматра, могу бити од интереса потпуно различите електроде.

Квантификација дислексичних тенденција

Како ЕЕГ метода прикупља сигнале који имају релативно мале амплитуде, претпроцесирање ЕЕГ сигнала представља важан корак у оквиру сваке ЕЕГ студије. Претпроцесирање може подразумевати различите кораке, а најчешће обухвата филтрацију у фреквенцијском домену, ререференцирање и усредњавање сигнала добијених са различитих електрода и отклањање артефаката услед трептаја. Након претпроцесирања, у домену анализе ЕЕГ сигнала често се користи и анализа можданих таласа (енг. *brainwaves*) који се односе на прорачун неуралне активности која припада одређеном фреквенцијском опсегу. Мождани таласи се деле на делта (0,5-4 Hz), тета (4-8 Hz), алфа (8-12 Hz), бета (12-30 Hz) и гама (>30 Hz) таласе. У наведеним студијама које се баве анализом дислексичних тенденција углавном је коришћен овај тип анализе, али не само са циљем чисте квантификације снаге можданих таласа у различитим регионима мозга, већ у циљу праћења повезаности активности различитих региона.

У [57], аутори су посматрали ЕЕГ испитанике током мировања, користећи снимак од 2 минута. Све електроде су референциране током обраде у односу на просечну вредност снимка са мастоидних електрода. Затим, урађена је интерполација на каналима који су имали превише изражене артефакте користећи сигнале са суседних канала. Снимак сваког испитаника је сегментиран на 30 епоха, свака дужине 4 секунде. Визуелном инспекцијом сваке од епоха у контексту артефаката који потичу од трептаја и мишићне активности је издвојено 10 епоха за сваког испитаника које не садрже артефакте, и ових 10 епоха је коришћено за даљу анализу. Електроде из ових епоха су ререференциране у односу на просек сигнала са свих електрода, пре вршења спектралне анализе и анализе функционалне повезаности. За анализу спектралне активности, рачунате су спектралне снаге за делта (0,5 – 4 Hz), тета (4 – 8 Hz), алфа (8 – 13 Hz), бета (13 – 30 Hz) и гама (30 – 48 Hz) таласе. Алфа спектар је, притом, подељен на ниже алфа таласе (8 – 10 Hz) и више алфа таласе (10 – 13 Hz). Релативне снаге су усредњене за свих 10 посматраних епоха. Анализа функционалне повезаности је урађена коришћењем *Phase Lag Index* параметра, који је посматран између сваке две електроде, засебно за сваку епоху и засебно за сваки тип можданих таласа [62]. На основу *Phase Lag Index* матрица које описују однос између сваке две електроде, прављен је *Minimum Spanning Tree* за сваку епоху, који карактерише повезаност између региона помоћу теорије графова [63]. У овој студији, праћени су следећи параметри за *Minimum Spanning Tree*: број листова, *betweenness centrality*, *eccentricity*, *diameter*, *hierarchy* и степен корелације.

У [58], је такође праћен ЕЕГ у стању мировања и анализа се заснивала на праћењу можданих таласа. На иницијалне сигнале је примењен *lowpass* филтер до 100 Hz, а канали са превеликим шумом су кориговани интерполацијом на основу суседних канала. ЕЕГ сигнали су додатно филтрирани користећи дигитални *bandpass* филтар од 0,5 – 30 Hz, смањена му је фреквенција одабирања на 512 Hz, и сви канали су ререференцирани на просечни сигнал са свих електрода. Снимци су подељени у епохе од по 2 s и подаци сваког испитаника су структурирани у 20 епоха које немају артефакте. За даљу анализу, посматрана је свака епоха засебно и сваки тип можданих таласа засебно, делта (0,5 – 4 Hz), тета (4 – 8 Hz), алфа (8 – 13 Hz), бета (13 – 30 Hz). Метода квантификације повезаности је поновљена из [57] и креирана је *Phase Lag Index* матрица, на основу које је рађена *Minimum Spanning Tree* анализа.

Spironelli et al. су у својој студији снимали ЕЕГ током лингвистичких задатака, а обрада се фокусирала на фреквенцијску анализу можданих таласа [59]. Урађена је корекција сирових ЕЕГ података спрам трептаја и артефаката који су настали усред покрета очију. Сигнали испитаника су подељени у 4 епохе за свако понављање, које обухвата 1024 ms пре стимулуса, 1024 ms директно после стимулуса, 1500 до 2524 ms после стимулуса и 2476 до 3500 ms после стимулуса. Ова времена су изабрана на основу претходних студија аутора. Овако подељени сегменти су додатно анализирани спрам артефаката и избачени су они који су сматрани превише зашумљеним. У студији су анализирани тета (4 – 8 Hz) и бета (13 – 30 Hz) таласи, тј. њихова нормализована снага. За статистичку анализу, посматране електроде су груписане у 4 региона, како би се пратио ниво симетрије и латерализације мождане активности: предњи леви регион (Io1, Fp1, F3, F7, F9), предњи десни регион (Io2, Fp2, F4, F8, F10), задњи леви регион (P7, P3, M1, T7, O1) и задњи десни регион (P8, P4, M2, T8, O2).

Žarić et al. су пратили повезаност мождане активности између различитих региона мозга током анализе приказаних речи и псеудоречи (псеудодонта), али се нису фокусирали на анализу можданих таласа већ су евалуирали повезаност сигнала са различитих канала на основу *Directed transfer function* методе [60]. Прикупљени сигнали су током аквизиције пропуштени кроз *lowpass* филтер са границом од 104 Hz. Сирови ЕЕГ сигнали су након аквизиције ререференцирани у односу на просек сигнала са мастоидних електрода, а затим филтрирани помоћу дигиталног *bandpass* филтра од 0,5 – 100 Hz. Прикупљени сигнали су затим подељени у епохе, од -500 до 900 ms у односу на приказ стимулуса који су од интереса за анализу. Извршена је корекција базне линије сигнала који припадајау датој епохи на основу периода од 500 ms пре стимулуса, а реакција испитаника је праћена у наредних 900 ms јер се сматра да се у том периоду дешавају све реакције на речи/псеудоречи које су од интереса. Епохе су затим анализирани, и свака епоха која је имала амплитуде веће од 150 μV на електродама са површине главе или електродама које су пратиле покрете очију је одбачена услед постојећег артефакта. Такође је урађено уклањање шума напајања од 50 Hz одузимањем синусоиде ове фреквенције у временском домену. За анализу повезаности између канала коришћена је *Directed transfer function* метода која враћа вредност између 0 и 1, где 1 карактеришује јасну повезаност канала [64].


Taskov et al. су у својој студији пратили како вежбање визуелних способности утиче на повезаност неуралне мреже задужене за читање код испитаника са дислексијом [65]. Анализа урађена у студији се заснивала на анализи можданих таласа и то по следећим фреквенцијским опсезима: делта (1,5 – 4 Hz), тета (4 – 8 Hz), алфа (8 – 13 Hz), бета1 (13 – 20 Hz), бета2 (20 – 30 Hz), гама1 (30 – 48 Hz) и гама2 (52 – 70 Hz). Снимци су сегментирани у епохе, где свака епоха траје 800 ms након приказивања текстуалног стимулуса. У анализу су укључене оне епохе које су биле без артефаката (са сигнаlima који не прелазе амплитуду од 200 μV). Пречишћени ЕЕГ сигнали су филтрирани са *bandpass* филтром од 1 – 70 Hz и *notch* филтром на 50 Hz. Анализа

повезаности је рађена за свако понављање, за сваку электроду засебно, и урађена је помоћу рачунања *Phase lag index* матрице.

2.3 Примена праћења покрета очију у дијагнози дислексије

Инструментација

Покрети очију омогућавају ефикасно визуелно узорковање информација и њихова анализа се користи у различитим областима, од психологије и друштвених наука преко неуромаркетинга па све до рачунарства [66]. Праћење покрета очију током читања или сличних задатака везаних за визуелну пажњу је од посебног интереса у истраживањима везаним за дислексију јер се очекује да ће постојати другачији обрасци у односу на оне код неуротипичних испитаника. Постоје различити уређаји који се могу користити за праћење покрета очију, али се могу поделити у две начелне групе, а то су носиви уређаји и бесконтактни уређаји. Примери инструмената који се могу користити за праћење покрета очију се налазе на Слици 3.



Слика 3. Примери уређаја за праћење покрета очију. Сlike преузете из [67] и прилагођене.

Уређаји за праћење покрета очију се заснивају на инфрацрвеним диодама и инфрацрвеним камерама на основу којих се, помоћу алгоритама обраде слике, одређују позиције очију и зеница. Инструменти најчешће имају опцију калибрације, током које се детектоване позиције зеница мапирају на жељени простор стимулуса – у студијама читања су то екран или папир на коме је приказан текст. Уређаји се могу значајно разликовати у смислу просторне и временске резолуције што може значајно утицати на даљи квалитет података. У Табели 2 је дат кратак преглед инструментације која је коришћена у студијама где су праћени покрети очију испитаника са дислексијом.

Табела 2. Преглед инструментације за праћење покрета очију у студијама дислексије.

Технологија	Тип уређаја	Фреквенција одабирања	Референца
Развијен од стране аутора	носив	Није наведено	[68]
<i>EYELINK I</i> (SR research, Отава, Канада)	носив	250 Hz	[69]
<i>Tobii 1750</i> уређај (<i>Tobii</i> , Стокхолм, Шведска)	бесконтактни	50 Hz	[15]
<i>Ober-2</i> (<i>Permobil Meditech</i> , Вобурн, Масачусетс, Сједињене Америчке Државе)	носив	100 Hz	[9]
<i>Medotics AG eye tracker</i> (<i>Medotics</i> , Базел, Швајцарска)	носив	60 Hz	[13]
<i>EyeLink 1000</i> (SR research, Отава, Канада)	бесконтактни	1000 Hz	[12]
<i>Pupil Core</i> (<i>Pupil Labs</i> , Берлин, Немачка)	носив	200 Hz	[14]
<i>iView X™ Hi-Speed 1250</i> систем (<i>SensoMotoric Instruments</i> , Телтоу, Немачка)	фиксирани	1250 Hz	[70]
<i>SMI RED-m</i> систем (<i>Gaze intelligence</i> , Париз, Француска)	бесконтактни	60 Hz	[1]

Pavlidis [68] је развио носиви систем за праћење покрета очију испитаника. У студији је наведена само просторна резолуција развијеног уређаја која износи 15' хоризонталног лука. *Prado et al.* су у својој студији користили носиви комерцијални систем *EYELINK I* (SR research, Отава, Канада) и прикупљали податке на фреквенцији одабирања од 250 Hz [69]. Аутори наводе да су праћени покрети само десног ока, и да је спроведена калибрација пре почетка снимања која је урађена у 9 тачака. *Rello et al.* у својој студији користе бесконтактни *Tobii 1750* уређај (*Tobii*, Стокхолм, Шведска) са фреквенцијом одабирања од 50 Hz [15]. *Benfatto et al.* су у својој студији користили носиви *Ober-2* (*Permobil Meditech*, Вобурн, Масачусетс, Сједињене Америчке Државе) са фреквенцијом одабирања која износи 100 Hz [9]. Аутори наводе ручну калибрацију пре почетка сваког снимања, и просторну резолуцију уређаја од 5' хоризонталног лука. *Asvestopoulou et al.* су у студији користили *Medotics AG eye tracker* (*Medotics*, Базел, Швајцарска) са фреквенцијом одабирања од 60 Hz [13]. Коришћени систем је бесконтактан и заснован је на две камере које имају резолуцију од по 1600×1200 пикселла. *Raatikainen et al.* су у својој студији користили *EyeLink 1000* (SR research, Отава, Канада) бесконтактни уређај са фреквенцијом одабирања од 1000 Hz [12]. Аутори наводе да је рађена калибрација између снимања уколико је примећен значајан померај главе испитаника или уколико је грешка калибрације прелазила 0,3 просторна степена. *El Hmimdi et al.* су спровели студију у којој су користили носиви уређај *Pupil Core* (*Pupil Labs*, Берлин, Немачка), са фреквенцијом одабирања од 200 Hz [14]. *Weiss et al.* су у свом истраживању користили *iView X™ Hi-Speed 1250* систем (*SensoMotoric Instruments*, Телтоу, Немачка) са фреквенцијом одабирања од 1250 Hz [70]. *iView X™ Hi-Speed 1250* је фиксиран систем који није носив, већ је потребно да се испитаник постави у одређени положај. Калибрација је урађена помоћу 13 тачака и валидирана пре и после читања текста помоћу региона од 1°×1° око две посебно намењене калибрационе тачке. *Jakovljevic et al.* су у својој студији користили *SMI RED-m* систем (*Gaze intelligence*, Париз, Француска) и аквизиција је рађена на 60 Hz [1]. Калибрација је спроведена у софтверу *SMI BeGaze 3.7* (*Gaze intelligence*, Париз, Француска), а калибрација је подразумевала постигнуту тачност у 5 тачака од 0,5° за обе осе.

Посматрајући наведене системе, може се уочити велики број различитих уређаја који су коришћени у студијама дислексије. У зависности од типа експеримента могу се користити носиви или бесконтактни уређаји, са тиме да сваки тип уређаја има своје предности и мане. Бесконтактни

уређаји су погоднији у сценаријима где се стимуси приказују на монитору, узимајући у обзир фиксни простор у оквиру ког је потребно пратити покрете очију нудећи лакше мапирање погледа на регионе од интереса у односу на носиве системе. Са друге стране, носиви уређаји допуштају слободно померање испитаника током експеримента, и лакши су за употребу уколико стимулуси немају предефинисан оквир у коме се приказују. Просторна и временска резолуција система такође играју значајну улогу, где је најчешће потребно направити компромис између приступачности уређаја и његових перформанси. Различити уређаји, поставке и калибрације такође дају различите степене просторне резолуције снимка, а сви ови фактори могу значајно утицати на обележја која су касније креирана из прикупљених сигнала.

Квантификација дислексичних тенденција

У студијама које се фокусирају на праћење покрета очију током читања, често се користи анализа догађаја очних покрета (енг. *eye movement events*) који имају више категоризација, али се најчешће деле у две главне групе, фиксације и сакаде. Фиксације представљају очне покрете где је померање споро и минимално и током којих се испитаник фокусира на одређени објекат, док су сакаде скоковити и брзи очни покрети током којих се тачка фокуса пребацује из једног региона у други. Инструменти за праћење покрета очију изворно дају временске секвенце координата тачке фокуса, а софтверска окружења која иду уз њих често имају имплементирани алгоритме помоћу којих се секвенца података дели на фиксације и сакаде. Подела секвенце погледа на сакаде и фиксације се може постићи помоћу више различитих алгоритама (попут примене прага брзине и прага просторне распршености) [71] и може се сматрати да софтверска решења коришћена у посматраним студијама примењују поуздане методе и дају резултате који су адекватни за даљу анализу.

Издавање обележја из сигнала очних покрета је најчешће коришћен приступ у студијама праћења очних покрета код испитаника са дислексијом, и ова обележја се користе као улаз у различите алгоритме машинског учења, као и за статистичке анализе. У неким студијама се користе конвенционална обележја која се најчешће добијају из софтвера за анализу покрета очију, док је циљ других студија укључивање нових обележја и њихова евалуација. Обележја коришћена у посматраним студијама се могу начелно поделити у 3 категорије, обележја заснована на фиксацијама, обележја заснована на сакадама и остала обележја, која комбинују фиксације и сакаде или не користе поделу очних покрета на догађаје. Преглед обележја заснованих на фиксацијама која су наведена у релевантној литератури се налази у Табели 3.

Посматрајући имплементирана обележја која се заснивају на фиксацијама, може се уочити широк спектар различитих приступа, укључујући и временске (средње, укупно време трајања) и просторне (средња вредност позиције, укупан пређени пут) приступе. Најзаступљенија обележја свакако представљају средње време трајања фиксација и укупан број фиксација током снимка.

Обележја изведена из сакада у студијама које се баве анализом очних покрета код особа са дислексијом су дате у Табели 4.

Табела 3. Преглед обележја из литературе изведених из фиксација.

Обележје	Референца
Средње време трајања фиксација	[69][9][13][15] [72][11][12][14][1]
Укупан број фиксација	[69][13][15][72] [11][12][1]
Укупно време трајања фиксација	[15] [11][12] [1]
Медијана времена трајања фиксација	[13] [11][70]
Средња вредност просторног распона фиксација	[9][72][14]
Стандардна девијација трајања фиксација	[9] [11]
Средња вредност брзине фиксација	[72][14]
Средња вредност позиције тачке фокуса током фиксација	[9][72]
Стандардна девијација позиције тачке фокуса током фиксација	[9][72]
Стандардна девијација просторног распона фиксација	[9][72]
Интерквартални опсег трајања фиксација	[70]
Проценат регресивних фиксација	[69]
Проценат прогресивних фиксација	[69]
Укупно трајање прогресивних фиксација	[69]
Укупно трајање регресивних фиксација	[69]
Стандардна девијација брзине фиксација	[72]
Средња вредност стандардне девијације позиције фокуса током фиксација	[9]
Стандардна девијација стандардне девијације позиције фокуса током фиксација	[9]
Средња вредност максималног растојања између две тачке током фиксација	[9]
Стандардна девијација максималног растојања између две тачке током фиксација	[9]
Средња вредност укупног пређеног пута током појединачних фиксација	[9]
Стандардна девијација укупног пређеног пута током појединачних фиксација	[9]
Трајање фиксација и просторни распон сакада у оквиру региона од интереса	[12]
Вредности хистограма за трајање фиксација и просторни распон сакада у оквиру региона од интереса	[12]
Медијана броја фиксација подељена са бројем речи	[70]
Интерквартални опсег трајања фиксација подељен бројем речи	[70]
Фреквенција фиксација	[1]

Преглед обележја која се заснивају на детекцији сакада даје нешто већи број различитих обележја у односу на она која се заснивају на фиксацијама, али суштински се не може рећи да су много више заступљена у истраживањима. Најзаступљеније обележје је средња вредност просторног распона сакада, са тиме да је и то обележје и даље мање заступљено од средњег времена трајања фиксација. Такође се може уочити, да је анализа брзине/убрзања заступљенија код сакада него код фиксација, што се оправдава већим распоном брзина сакада, узимајући у обзир да су сакаде бржи покрети од фиксација.

Табела 4. Преглед обележја из литературе изведених из сакада.

Обележје	Референца
Средња вредност просторног распона сакада	[9][72][13][11][12][14]
Укупан број сакада	[72][11][1]
Средње време трајања сакада	[12][14][1]
Стандардна девијација просторног распона сакада	[9][72][11]
Средња вредност брзине сакада	[72][14]
Средња вредност позиције тачке фокуса током сакада	[9][72]
Стандардна девијација позиције тачке фокуса током сакада	[9][72]
Укупно време трајања сакада	[1]
Средње време трајања сакада	[9]
Стандардна девијација трајања сакада	[9]
Стандардна девијација брзине сакада	[72]
Медијана просторног распона сакада	[13]
Средња вредност стандардне девијације позиције фокуса током сакада	[9]
Стандардна девијација стандардне девијације позиције фокуса током сакада	[9]
Средња вредност максималног растојања између две тачке током сакада	[9]
Стандардна девијација максималног растојања између две тачке током сакада	[9]
Средња вредност укупног пређеног пута током појединачних сакада	[9]
Стандардна девијација укупног пређеног пута током појединачних сакада	[9]
Проценат регресивних сакада	[14]
Проценат прогресивних сакада	[70]
Амплитуда разлике тачке фокуса између два ока после сваке сакаде	[14]
Медијана времена трајања прогресивних сакада	[70]
Медијана времена трајања регресивних сакада	[70]
Медијана просторног распона сакада	[70]
Медијана просторног распона прогресивних сакада	[70]
Медијана просторног распона регресивних сакада	[70]
Медијана максималне вредности брзине сакада	[70]
Медијана максималне вредности брзине прогресивних сакада	[70]
Медијана максималне вредности брзине регресивних сакада	[70]
Медијана максималне вредности убрзања сакада	[70]
Медијана максималне вредности убрзања прогресивних сакада	[70]
Медијана максималне вредности убрзања регресивних сакада	[70]
Број прогресивних сакада подељен са временом читања	[70]
Број регресивних сакада подељен са временом читања	[70]
Број сакада подељен са временом читања	[70]
Фреквенција сакада	[1]

Преглед обележја која се издвајају неvezано од поделе погледа на фиксације и сакаде, или комбинују податке од фиксација и сакада је дат у Табели 5.

Табела 5. Преглед обележја изведених из очних покрета која нису директно изведена само из фиксација/сакада.

Обележје	Референца
Укупан пређени пут	[72][11]
Укупан број трептаја	[72][11]
Укупан број кратких прогресивних покрета очију	[13]
Укупан број речи које су фокусиране више пута	[13]
Укупан број посета региону од интереса	[15]
Просечно време проведено у региону од интереса	[15]
Густина путање кретања ока (енг. <i>scan path</i>)	[72]
Укупно време трајања трептаја	[72]

Може се приметити да је укупан број обележја из литературе која се не заснивају на фиксацијама и сакадама значајно мањи у односу на она која се из њих директно изводе. Фиксације и сакаде представљају фундаментално другачије делове процеса усвајања визуелног садржаја, и из овог разлога постоје јасне предности њихове засебне анализе.

Као најзаступљеније обележје из свих посматраних обележја се издваја средње време трајања фиксација, са тиме да се у четири најкоришћенија обележја изведена из покрета очију налази и укупан број фиксација и укупно време трајања фиксација. Испитаници са дислексијом најчешће имају потешкоћа у читању услед чега се очекује већи број фиксација и њихово дуже трајање. Још једно обележје које се често користи у литератури, а није директно изведено из анализе покрета очију је време читања. Овај параметар се може лако измерити и користи се као прелиминарни индикатор способности читања, а врло је близак укупном времену трајања фиксација пошто сакаде и трептаји у већини случајева трају веома кратко. Поред временског трајања фиксација, у литератури се налазе и обележја везана за сакаде од којих је најзаступљенија средња вредност просторног распона сакада. Испитаници са дислексијом имају тенденцију да праве већи број мањих сакада због чега се очекује да овај параметар има ниже вредности код групе са дислексијом у односу на претходну. Сличан аргумент се може применити и на укупан број сакада који је такође заступљен у литератури.

3 Разликовање дислексичних образаца применом метода статистичке анализе

Статистичко поређење добијених резултата омогућава да се са одређеним степеном сигурности, а на основу математички засноване методологије, утврди да ли постоји значајна разлика између одређених појава [73,74]. У студијама које се баве дислексијом, статистичка анализа је веома распрострањена, и ово поглавље представља преглед студија које су квантификовале одређене биометријске карактеристике на којима је затим спроведена статистичка анализа како би се дошло до значајних закључака.

Peyrin et al. су спровели студију у којој су истражили везу између визуелне пажње и фонолошких способности код одраслих особа са дислексијом, посматрајући резултате два различита теста и снимке фМР [44]. У студији су учествовала два испитаника са дислексијом француског матерњег језика, од којих је један имао изражен дефицит фонолошких способности и очувану визуелну пажњу, док је други имао очуване фонолошке способности, али је показао лоше способности приликом тестова визуелне пажње. Истраживање је показало да особе са дислексијом могу имати потешкоће са различитим вештинама. Анализа мождане активности са фМР снимака је такође ишла у прилог резултатима тестова фонолошке способности и визуелне пажње. Мождана активност испитаника са дислексијом је била слична можданој активности контролне групе током задатака у којима испитаник није имао потешкоћа, али у тестовима где је способност испитаника са дислексијом нарушена постојале су значајне разлике у односу на контролну групу. Како су испитаници са дислексијом имали потешкоће са различитим вештинама, и спрам тога показивали другачије мождане активности, закључак студије је да хетерогеност дислексије као поремећаја мора бити узета у обзир приликом студија које се баве можданом активношћу.

Анализа можданих активности током задатака на јапанском језику који тестирају визуелну пажњу је спроведена на популацији одраслих (12 контролних испитаника и 12 испитаника са дислексијом) помоћу фМР снимака [45]. Током истраживања испитаницима су приказивани слова, цифре, симболи јапанског писма и псеудо-слова и праћена је њихова мождана активност током препознавања приказаних стимулуса. Разлике у можданој активности су постојале између контролне групе и групе са дислексијом у више различитих региона. Током симултаног приказа више симбола, контролна група је имала појачану активност париеталне регије у односу на активност која настаје током праћења појединачних симбола. Ова појачана активност није била присутна за испитанике са дислексијом. Такође је уочена слабија активност у десном горњем париеталном лобулу код испитаника са дислексијом у односу на контролне, неvezано од типа стимулуса.

Beneventi et al. су спровели истраживање у коме су анализирали способности радне меморије код деце са дислексијом помоћу фМР [46]. У испитивању је учествовало 12 испитаника са дислексијом и 14 контрола са просеком година између 13 и 14, матерњег норвешког језика. Испитаницима су секвенцијално приказивана слова, а дате су инструкције да реагује ако се приказано слово поклапа са претходно приказаним (1. сценарио) или ако се приказано слово поклапа са претпоследње приказаним словом (2. сценарио). Резултати показују смањену мождану активност у префронталним и париеталним кортексима као и у малом мозгу код испитаника са дислексијом у односу на контролне.

Поред визуелне пажње, радне меморије и фонолошких способности, анализирана је и мождана активност испитаника са дислексијом током писања [47]. У студији је учествовало 14 испитаника са дислексијом и 14 контролних испитаника са просеком од 9,5 година чији је матерњи језик француски. Студија је обухватала тестирање спеловања, рукописа и покретљивости шаке, а фМР снимци су прављени током задатака диктирања речи. Резултати су показали да контролни испитаници и испитаници са дислексијом имају сличне способности покретљивости шаке и брзине писања, али да група са дислексијом има израженије потешкоће у спеловању као и лошији рукопис. Анализа можданих активности показује да група са дислексијом током задатка има слабије активности и у одређеним централним и периферним регионима мозга у односу на контролну.

Yang et al. су спровели истраживање у коме су пратили неуралне активности испитаника са дислексијом и контролних испитаника помоћу фМР чији је матерњи језик кинески [48]. У студији је учествовало 14 испитаника са дислексијом и 16 контролних испитаника са просеком од 11 година. Експеримент је обухватао приказ 30 симбола кинеског језика и 30 псеудо симбола где су испитаници требали да класификују сваки симбол. Уз симболе су пуштани снимци изговора различитих кинеских симбола, и аудиторни стимулуси су били синхорнизовани са визуелним приказом, али је испитаницима дата инструкција да одлуку доносе само на основу визуелног приказа. Резултати студије су показали разлике између контролне групе и групе са дислексијом у повезаности и активности већег броја можданих структура и указале на разлике у неуралним механизмима на примеру језика са логографским писмом.

Праћење и квантификација мождане активности код испитаника са дислексијом је, поред медицинске слике, рађена и помоћу ЕЕГ-а. *Fraga González et al.* су спровели истраживање у коме су помоћу ЕЕГ-а пратили мреже повезаности можданих структура код испитаника са дислексијом и контролних испитаника [57]. Мождана активност је праћена у стању мировања и у студији је учествовало 29 испитаника са дислексијом и 15 контрола, у просеку између 8 и 9 година, чији је матерњи језик холандски. Испитаници су седели мирно, затворених очију и праћена им је мождана активност током два минута. На основу ових снимања урађена је графовска анализа и поређене су мреже повезаности можданих структура код испитаника са дислексијом и контролних испитаника. Резултати студије су указали да испитаници са дислексијом имају слабију повезаност неуралних структура у домену тета таласа у односу на контролну групу.

Снимање ЕЕГ-а током мировања код испитаника са дислексијом и контролних испитаника је рађено и на испитаницима чији је матерњи језик кинески [58]. У студији је учествовало укупно 67 деце, 27 са дислексијом и 40 контрола. На основу ЕЕГ податка је креиран граф са циљем анализе повезаности различитих региона мозга у домену делта, тета, алфа и бета таласа. Резултати студије показују да је повезаност региона мозга у бета домену код испитаника са дислексијом смањена у односу на контролне, и да испитаници са дислексијом имају структуру графа која је линеарнија, док код контролних испитаника граф има више гранања и цикличних елемената.

ЕЕГ је коришћен и у студијама где су се анализирале разлике у неуралним механизмима контролних испитаника и испитаника са дислексијом током различитих задатака [59]. У студији је учествовало 14 испитаника са дислексијом и 28 контролних испитаника са просеком од 10 година и италијанским матерњим језиком. Испитаницима су приказивани парови речи, прво једна па друга реч и постављена су три различита задатка. У првом задатку испитаници су требали да одговоре да ли се речи римују, у другом да ли су речи семантички повезане и у трећем да ли су речи писане истом величином слова (велика слова или мала слова). Ова три задатка су анализирала фонолошке, семантичке и ортографске способности испитаника, а током задатака је праћена мождана активност помоћу ЕЕГ-а. Испитаници са дислексијом су показали спорије реакције од

контролне групе као и индикаторе дисфункционалности у можданим активностима, укључујући десну латерализацију у фронталним регијама у свим задацима и леву латерализацију у задњем делу мозга током фонолошког и ортографског задатка.

Žarić et al. су спровели студију у којој су истражили да ли нарушеност неуралне повезаности има везе са степеном потешкоћа у читању [60]. У студији су учествовале три групе испитаника, испитаници са дислексијом и тешким поремећајем читања, испитаници са дислексијом и умереним поремећајем читања и контролна група. Просек година испитаника је био 9 и матерњи језик свих испитаника је био холандски. Испитаницима су приказиване речи писане регуларним словима као и речи писане псеудофонтом и праћена је реакција испитаника. Резултати студије су показали да деца са дислексијом имају смањену повезаност неуралне активности између одређених региона и да обрасци (не)повезаности мождане активности током задатка корелишу са степеном потешкоћа у читању.

Taskov et al. су у свом истраживању анализирали да ли визуелне вежбе могу приближити групу са дислексијом контролној групи у контексту неуралних активности [65]. Аутори наводе да постоје разлике у можданим активностима између групе са дислексијом и контролне групе, али анализирају да ли се те разлике могу смањити након визуелних вежби, тј. да ли вежбање визуелних способности може помоћи успостављању нових неуралних путева. У студији је учествовало 22 испитаника са дислексијом и 21 контролни испитаник са распоном година између 8 и 9 и бугарским матерњим језиком. Испитаницима су приказиване речи на екрану и од њих је тражено да изговоре речи наглас, а током експеримента им је праћена мождана активности помоћу ЕЕГ-а. Експерименти су спровођени пре и после сесија визуелних вежби и показано је да су се метрике графова повезаности можданих таласа испитаника са дислексијом приближиле метрикама контролне групе након вежби. Ова студија је указала на значај који визуелне вежбе могу имати као на симптоме дислексије као и на саме неуралне механизме, истичући значај праћења и анализе приступа визуелног узорковања током читања код испитаника са дислексијом.

Анализа покрета очију код испитаника са дислексијом такође представља значајан правац истраживања и она је спровођена још од 90-их година двадесетог века. *Pavlidis* је у једној од најранијих студија приказао да се покрети очију код испитаника са дислексијом разликују од покрета очију контролне групе [68]. У студији је учествовало 12 испитаника са дислексијом и 12 контролних испитаника, са распоном година од 10 до 16. Током експеримента испитаници су добили инструкцију да што брже прате лампице које се секвенцијално укључују и искључују. Праћење покрета очију испитаника је рађено помоћу носивог система које је развио аутор. Резултати студије су показали да испитаници са дислексијом праве много већи број покрета очију у односу на контролне испитанике услед лутања погледа и немогућности задржавања фокуса у једној тачки.

Prado et al. су спровели једну од првих студија која се бавила анализом покрета очију код групе са дислексијом и контролне групе током задатка визуелне претраге и читања [69]. Аутори су желели да истраже да ли постоје разлике у способностима визуелне пажње у задацима са и без читања. У студији је учествовало 14 испитаника са дислексијом и 14 контролних испитаника са просеком од 11 година, француског матерњег језика. Током задатка визуелне претраге испитаницима је приказан текст у коме су испитаници требали да преброје колико пута се у речима појављује слово „Р“. Други задатак је од испитаника захтевао да прочитају неколико редова текста наглас. Праћење покрета очију је урађено помоћу *EYELINK I* система (*SR research*, Отава, Канада) на фреквенцији од 250 Hz. Резултати студије су показали да нема значајних разлика у обрасцима очних покрета између група када је у питању задатак визуелне претраге. Са друге стране, постоје значајне разлике између група када је у питању задатак читања. Такође, изведен је

закључак да се механизми визуелне пажње разликују између два задатка код контролне групе, међутим та разлика код испитаника са дислексијом није у довољној мери присутна. Овим је указано на то да контролни испитаници лакше прилагођавају своју визуелну пажњу природи задатка, док испитаници са дислексијом имају потешкоће у овом погледу.

Анализе покрета очију и њихових карактеристика код испитаника са дислексијом су рађене и на српском језику. *Jakovljevic et al.* су у својој студији посматрали 18 испитаника са дислексијом и 18 неуротипичних испитаника са распоном година од 8 до 12 чији је матерњи језик српски [1]. Аутори су у студији користили мултимодални систем за праћење [75], који је поред покрета очију пратио и електродермалну активност (психогалвански рефлекс), откуцаје срца, као и ЕЕГ сигнале. Поставка експеримента је подразумевала да испитаник у себи чита текст приказан на 13 засебних страница, са тим да свака страница има другачију конфигурацију боја за приказ. Прва приказана страница је увек била црни текст са белом позадином а преосталих 12 страница је имало псеудослучајан редослед са измењеном или бојом позадине или додатим провидним филмом (енг. *overlay*) у црвеној, плавој, жутој, љубичастој, тиркизној и наранџастој боји. Аутори су се фокусирали на статистичку анализу поређећи контролну групу и групу са дислексијом и њихове реакције на различите приказе текста. Утврђено је да су тиркизна позадина, тиркизни *overlay* и жута боја позадине корисне за читаоце са дислексијом, јер су постигли најкраће временско трајање задатака читања када су коришћени ови прикази. Установљено је да постоје и разлике у ЕЕГ, срчаној и електродермалној активности на одређеним приказима текста, као и да постоје разлике између групе са дислексијом и контролне групе на параметрима који описују очне покрете у скоро свим сценаријима приказа текста.

4 Препознавање дислексичних образаца помоћу метода машинског учења

Поред статистичке анализе, један од распрострањених приступа у студијама дислексије је примена алгоритама машинског учења. Ако се усвоји да статистичка анализа служи као алат за боље разумевање и уочавање разлика које постоје између неуротипичне групе и групе са дислексијом, алгоритми машинског учења се могу тумачити као алат који на основу мерења може да предвиди стање испитаника. Конкретно, посматрајући прикупљене биометријске податке, алгоритми машинског учења коришћени су за класификацију испитаника са дислексијом и неуротипичних испитаника.

У литератури, машинско учење примењено је у анализи неуралних структура помоћу структурне магнетне резонанце у циљу класификације испитаника са дислексијом и контролних испитаника [51]. Студија је имала две фазе, где је у првој учествовало 22 особе са дислексијом и 27 контрола, а у другој фази је учествовало 60 испитаника са дислексијом и 816 контролних испитаника. На подацима из прве базе је спроведена екстракција обележја из снимака магнетне резонанце, и примењен је *Support vector machine (SVM)* алгоритам који је евалуиран методом крос-валидације са поделом по испитаницима (енг. *subject-wise cross-validation*). Затим је *SVM* алгоритам обучен на свим подацима из прве фазе и евалуиран на подацима прикупљеним током друге фазе. Добијена је тачност од 80% за евалуацију на првом скупу података и тачност од 59% на другом скупу података. Као најинформативнија обележја издвајају се она добијена из левог окципиталног гируса и доње паријеталне лобуле.

Rello et al. се наводе као први рад у коме се детекција дислексије врши на основу карактеристика очних покрета [15]. У студији аутори користе различите одлике очних покрета и алгоритме машинског учења како би испитанике класификовали у групу са дислексијом и неуротипичну групу. У студији је учествовало 48 испитаника са дислексијом и 49 неуротипичних испитаника са распоном година од 11 до 54 чији је матерњи језик шпански. Сваки испитаник је читао 12 различитих текстова (сваки текст на различитом типу фонта) приказан на белој позадини са црним словима. Анализа покрета очију је рађена помоћу *Tobii 1750* уређаја (*Tobii*, Стокхолм, Шведска) са фреквенцијом одабирања од 50 Hz-а. За класификацију групе са дислексијом и неуротипичне групе је коришћен *SVM* алгоритам и добијена је тачност класификације од 80,18%.

Студија са сличним концептом и нешто већим бројем испитаника је спроведена од стране *Benfatto et al.* [9]. У студији је учествовало 97 испитаника са дислексијом и 88 контролних испитаника са распоном година од 9 до 10 и шведским матерњим језиком. Током експеримента испитаницима је приказан текст на листу папира, црним словима на белој позадини. Испитаници су читали текст, а покрети очију су им праћени помоћу носивог система *Ober-2 (Permobil Meditech, Вобурн, Масачусетс, Сједињене Америчке Државе)* са фреквенцијом одабирања која износи 100 Hz. У студији је анализирано 168 различитих обележја очних покрета и имплементиран је алгоритам за селекцију обележја у комбинацији са *SVM* класификатором. Највећа постигнута тачност је 95,6% што указује на то да је са великом поузданошћу могуће раздвојити испитанике са дислексијом и неуротипичне испитанике на основу њихових покрета очију током читања.

Prabha et al. су у неколико својих студија истраживали различите могућности за класификацију испитаника из базе података прикупљене у [9]. У првој својој студији, *Prabha et al.* су испробали неколико различитих алгоритама машинског учења као класификаторе испитаника на групу са дислексијом и неуротипичну групу [76]. У тој студији, аутори су користили само обележја

изведена из фиксација и комбиновали су алгоритме машинског учења са методом за рекурзивни одабир обележја. Аутори су добили највећу могућу тачност класификације за алгоритам *k nearest neighbours* (KNN) која је износила 95%. У својој следећој студији, *Prabha et al.* су испробали још различитих алгоритама машинског учења и узели су у обзир обележја изведена из фиксација и сакада [72]. Најбоља добијена тачност је износила 95,6% и остварена је за *SVM* класификатор са посебном хибридном *particle swarm optimization* врстом керна. У својим даљим истраживањима, *Prabha et al.* су тестирали могућности класификације користећи још различитих алгоритама машинског учења посматрајући различите групе обележја и постигли највећу тачност од 96% [11,77].

Asvestopoulou et al. су спровали студију у којој су посматрали 32 испитаника са дислексијом и 37 контролних испитаника чији је матерњи језик грчки [13]. Распон година испитаника је од 8,5 до 12,5 и током експеримента су читали два параграфа текста приказаног на екрану монитора. Покрети очију испитаника су праћени помоћу *Medotics AG eye tracker* (*Medotics*, Базел, Швајцарска) са фреквенцијом одабирања од 60 Hz. Посматрана су различита обележја изведена из фиксација и сакада од којих је помоћу *LASSO* регресије биран подскуп доминантних обележја која су коришћена за обучавање класификатора. Остварена је тачност од 97% са *SVM* алгоритмом користећи само три обележја: дужина сакаде, број кратких прогресивних покрета и број речи које су више пута биле у оквиру фиксација.

Сprovedена су и истраживања која су се фокусирали на детекцију дислексије узимајући у обзир спектар способности читања. *Raatikainen et al.* су у својој студији посматрали 165 испитаника са просеком година од 12,5 чији је матерњи језик фински [12]. На основу перформанси читања постављен је праг и 30 испитаника са способностима читања испод прага је издвојено као група са дислексијом, док је осталих 135 сматрано неуротипичним. Иако груба за успостављање дијагнозе дислексије, ова претпоставка је уведена од стране аутора јер су желели да истраже могућности класификације потешкоћа у читању на скупу који представља континуални спектар способности читања, сматрајући да су испитаници са дислексијом на дну тог спектра. Током експеримента, испитаници су урадили 10 задатака у којима су требали да читају по 4 реченице текста и њихови покрети очију су праћени *EyeLink 1000* (*SR research*, Отава, Канада) уређајем са фреквенцијом одабирања од 1000 Hz. На основу фиксација и сакада су издвојена различита обележја, уз помоћ примене *random forest* (RF) је извршен одабир релевантних обележја а затим је на њима обучен *SVM* класификатор. Највиша остварена тачност је износила 89,7%.

El Hmimdi et al. су спровели студију у којој су спровели класификацију испитаника на групу са дислексијом и неуротипичну групу на основу очних покрета током два различита типа задатака [14]. У студији су анализирани покрети очију прикупљени користећи 4 различите поставке, а у свакој поставци је снимљено 46 испитаника са дислексијом и 41 контрола. Матерњи језик испитаника је био француски, а просек година испитаника је био око 15. Прве две поставке су подразумевале праћење лампица погледом док су друге две поставке подразумевале читање два различита текста. Покрети очију током експеримента су праћени помоћу *Pupil Core* (*Pupil Labs*, Берлин, Немачка) уређаја, са фреквенцијом одабирања од 200 Hz. Обележја су извучена из фиксација и сакада као и из брзина и амплитуда брзине несегментираних очних покрета и коришћена су за обучавање различитих алгоритама машинског учења укључујући и неуралне мреже. За поставке у којима су лампице праћене погледом, највећа тачност класификације испитаника је била 81,25% и 77,3% док је за задатке читања тачност у једном случају била 81,25%, а у другом 70,2%. Закључци студије иду у прилог томе да одабир текста који се користи за експеримент може веома утицати на сепарабилност класа испитаника, као и да се дислексични обрасци могу детектовати и помоћу задатака који не подразумевају читање.

Табела 6. Преглед основних информација о студијама које користе праћење покрета очију за истраживање дислексије.

Референца	Година	Контролни + испитаници са дислексијом	Узраст	Матерњи језик	Метода
<i>Pavlidis</i> [68]	1981	12+12	10-16	енглески	статистика
<i>Prado et al.</i> [69]	2007	14+14	11 ± 1	француски	статистика
<i>Rello et al.</i> [15]	2015	49+48	11-54	шпански	машинско учење
<i>Benfatto et al.</i> [9]	2016	88+97	9-10	шведски	машинско учење
<i>Asvestopoulou et al.</i> [13]	2019	37+32	8.5-12.5	грчки	машинско учење
<i>Prabha et al.</i> [76]	2019	88+97	9-10	шведски	машинско учење
<i>Prabha et al.</i> [72]	2020	88+97	9-10	шведски	машинско учење
<i>Appadurai et al.</i> [11]	2021	88+97	9-10	шведски	машинско учење
<i>Appadurai et al.</i> [77]	2021	88+97	9-10	шведски	машинско учење
<i>Jakovljević et al.</i> [1]	2021	18+18	8-12	српски	статистика
<i>Raatikainen et al.</i> [12]	2021	135+30	≈12,5	фински	машинско учење
<i>El Hmimdi et al.</i> [14]	2021	41+46	15 ± 2,5	француски	машинско учење
<i>Nerusil et al.</i> [16]	2021	88+97	9-10	шведски	машинско учење
<i>Weiss et al.</i> [70]	2022	24+24	≈24	мађарски	машинско учење

Weiss et al. су спровели студију у којој су испитали могућности препознавања дислексије на основу очних покрта и на основу бихејвиоралних мера тј. резултата тестова језичких способности [70]. У испитивању је учествовало 24 испитаника са дислексијом и 24 неуротипичних испитаника са просеком година око 24. Матерњи језик испитаника је био мађарски и током експеримента за праћење покрета очију испитаници су читали текст приказан на екрану црним словима на белој позадини. Током експеримента су праћени покрети левог ока помоћу *iView X™ Hi-Speed 1250* система (*SensoMotoric Instruments*, Телтоу, Немачка) са фреквенцијом одабирања од 1250 Hz. Поред експеримента за праћење покрета очију, спроведена је и мађарска адаптација *Differential Diagnosis Dyslexia Maastricht Battery* теста помоћу ког су добијене евалуације различитих језичких способности испитаника попут читања речи и псеудоречи, брисања фонема, брзог именовања и др. Затим је имплементирано 6 различитих метода за одабир обележја које су комбиноване са различитим класификаторима и добијена је тачност од 76,25% за класификатор заснован на обележјима покрета очију и 92,91% за класификатор који је обучен на обележјима изведених из тестова језичких способности.

Nerušil et al. се нису фокусирали на обележја изведена из очних покрета, већ су испитали могућност коришћења сирових сигнала очних покрета са конволуционим неуралним мрежама [16]. У студији је коришћена база података прикупљена у [9], али уместо обележја, коришћени су низови x и y координата тачке фокуса у времену. Ови низови су аугментирани помоћу неколико различитих алгоритама како би се постигле секвенце једнаке дужине, а затим су на тим секвенцама обучаване конволуционе неуралне мреже. Највећа добијена тачност је 96,6% указујући на то да је могуће помоћу неуралних мрежа препознати дислексичне обрасце читања без класичне екстракције обележја.

За истраживање приказано у овој дисертацији су од посебног интереса студије које користе праћење покрета очију како би се анализирале дислексичне тенденције, и преглед њихових основних информација је дат у Табели 6. Оно што је важно нагласити, је да у литератури не постоји студија која се бави класификацијом дислексичних образаца очних покрета на српском језику. Постоји студија која прати очне покрете код неуротипичних испитаника и испитаника са дислексијом [1], али се у оквиру те студије врши само статистичка анализа.

5 Терапија дислексије и асистивне технологије

Различите методе за успостављање дијагнозе и праћења стања се развијају са крајњим циљем да се особама са дислексијом олакша процес читања и усвајања градива. У зависности од потреба особе са дислексијом, могуће је укључити различите видове терапије или асистивних технологија. Код деце је рано успостављање дијагнозе од посебног значаја зато што је успешност терапије већа уколико је примењена у фази када дете учи да чита и пише [78]. Дислексија може имати више манифестација и језичке потешкоће могу бити различите, тако да свака особа захтева сопствени режим третмана. Терапија се најчешће ослања на вежбање конкретних језичких вештина са којима дете има потешкоће, комбинујући знање стручњака из различитих области и укључивањем различитих чула током вежби. Један од најраспрострањенијих приступа у терапији дислексије је *Orton-Gillingham* приступ [79]. Овај приступ подразумева јасно структуриран план рада, који је прилагођен појединцу или малој групи, са тиме да се секвенцијално уче различите језичке вештине са фокусом на учење читања на нивоу речи. Током рада на свакој појединачној вештини користи се приступ заснован на више чула/активности, попут читања слова наглас и писања тог слова руком у пени.

Поред различитих конвенционалних приступа језичкој терапији постоји и широк спектар асистивних и терапеутских технологија. Један од таквих приступа је представљен у [80] и заснива се на компјутерским играма. Ова студија приказује процес дизајнирања такозваних озбиљних игара (енг. *serious games*) које се заснивају на тачно одређеним аспектима које је потребно испратити код посматране циљне групе, а конкретно у студији код деце са дислексијом узраста 5-10 година. Развијена игрица се може користити на рачунару или паметном уређају без додатне опреме, и базира се на склапању различитих форми слагалица. Склапање слагалица у игрици подразумева коришћење различитих језичких вештина, које се сматрају значајним за терапију дислексије, и на тај начин се кроз забаву, самостално, могу спровести одређене терапијске активности. Једна слична студија се бавила лонгитудиналном евалуацијом игрице која се заснива на *Kinect* (Редмонд, Вашингтон, Сједињене Америчке државе) технологији [81]. Ова технологија омогућава бесконтактну интеракцију са игрицом на основу покрета тела, а игрица обухвата различите делове који су посебно намењени за детекцију и терапију дислексије. У оквиру студије су лонгитудинално праћена деца, и евалуацијом њихових језичких способности је установљен и потврђен позитиван терапеутски утицај игрице.

У контексту терапије дислексије, користе се и приступи засновани на музици. *Habib et al.* тестирају посебно развијену методу когнитивно-музичког тренинга (енг. *Cognitivo-Musical Training*) [82]. Метода се заснива на три принципа, упостављању аналогije између музике и језика, праћењу временских и ритмичких компонената музике и на интеграцији различитих чула. Ова три принципа су коришћена за развијање терапије која се не бави директно језичким способностима, а метода је тестирана на 8 испитаника са дислексијом, узраста од 8 до 12 година. Терапија је трајала 18 часова распоређених током три узастопна дана у једној групи или 6 недеља у другој. Обе групе су показале побољшање језичких способности, са израженијим побољшањем у групи која је имала терапију у 3 узастопна дана.

Поред различитих терапеутских алата, постоји и велики број асистивних технологија које могу бити од користи особама са дислексијом [83]. Асистивне технологије се често заснивају на конверзији текста у говор [84], с обзиром да се тиме превазилазе потешкоће у читању, али могу се односити и на различите алате за модификацију приказа текста. Многа истраживања се баве утицајем визуелне стратегије приказа текста на симптоме дислексије, укључујући фонт [15],

проред [85] и боју [85,86], што поставља основе за развијање алата за модификацију приказа текста. Као резултат постојећих истраживања, успостављен је велики број различитих смерница и упутстава за приказе садржаја како би био лакши за усвајање особама са дислексијом [87–89], а постоје и посебно дизајнирани фонтови текста [90]. Уз развијање дигиталних технологија, примене ових смерница у виду различитих алата који могу служити за модификацију већ креираног садржаја, представљају обећавајући корак за приступачну и ефикасну помоћ особама са дислексијом.

6 База података

У оквиру анализа које ће бити приказане у наредним поглављима, коришћена је база података прикупљена у студији спроведеној од стране *Jakovljević et al* [1]. Изворна база податка из студије се састојала од 18 испитаника са дислексијом и 18 контролних испитаника али је за анализу приказану у овој дисертацији коришћено 15 контролних испитаника и 15 испитаника са дислексијом јер преостали испитаници нису имали адекватне податке за ову врсту анализе услед мањег броја сегмената и кратког времена читања (мање од 5 s) што указује на недовољан фокус на приказани текст.

Распон година контролне групе је био од 7 до 13 година са средњом вредношћу година од 9,67. Распон година групе са дислексијом је био такође од 7 до 13 година, а просек година је износио 9,93. Контролна група се састојала од 7 дечака и 8 девојчица док је група са дислексијом имала 4 дечака и 11 девојчица. Испитаници су могли да одустану од тестирања у било ком тренутку. У консултацији са сертификованим логопедом, испитаници са дислексијом су одабрани из неколико основних школа у Београду. Контролни испитаници су одабрани насумично из три основне школе у Београду. Сва деца која су учествовала у експерименту, имала су нормалан (или коригован до нормалног) вид. Деца су учествовала у студији у преподневним часовима у оквиру редовног распореда наставе.

Током експеримента, деца су се налазила у изолованој, тихој и светлој просторији са особом која је водила експеримент, како би се обезбедили услови за рад и елиминисали спољњи утицаји. Деца су током експеримента седела на столицама за столом испред компјутерског монитора и тастатуре. Величина екрана је била 48 cm × 27 cm, осветљеност екрана је подешена на 90%, растојање од екрана је било 62 cm. Коришћен је и наслон за браду тако да је положај главе/очију у односу на монитор био исти за све испитанике. Током експеримента, сваки испитаник је прочитао 13 сегмената текста издвојених из стандардизоване приче за основну школу под називом „Свети Сава и сељак без среће“.

На почетку експеримента, испитаници су добили инструкције да, у себи, прочитају текст са приказане презентације (један слајд одговара једном сегменту текста) и да притисну *space* тастер за следећи слајд презентације. Експеримент је спроведен применом псеудо-случајног редоследа боја позадине/*overlay*-а, где је сваки сегмент имао засебну конфигурацију боја. Први сегмент је увек био црни текст на белој позадини а осталих 12 сегмената је приказано користећи шест боја: црвену, плаву, жуту, наранџасту, тиркизну и љубичасту. Свака боја је коришћена и као позадина и као *overlay* дајући укупно 12 комбинација поред црног текста на белој позадини.

Текст је припремљен и представљен у оквиру софтвера *SMI Experiment center 3.7 (Gaze intelligence*, Париз, Француска), задржавајући исту величину текста и фонт за сваки слајд, централно поравнат, приближно исте дужине. Све нијансе боја коришћене за дизајнирање слајдова (стимулуса) дефинисане су у оквиру *RGB* модела боја, а свака појединачна боја је изражена као тројка *RGB* вредности ($[R,G,B]$), где вредност сваке примарне компоненте може да се креће у распону од 0 до 255. У конфигурацијама где се мењала боја позадине текст је остајао црн $[0,0,0]$ а боје позадине су:

- црвена $[255,0,0]$;
- плава $[0,0,255]$;
- жута $[255,255,0]$;


- наранцаста [255,128,0];
- љубичаста [255,0,128];
- тиркизна [0,255,255].

За слајдове на којима је коришћен *overlay*, коришћене су следеће боје позадине и текста:

- црвена: текст [128,0,0], позадина [255,128,128];
- плава: текст [0,0,128], позадина [128,128,255];
- жута: текст [128,128,0], позадина [255,255,128];
- наранцаста: текст [128,64,0], позадина [255,192,128];
- љубичаста: текст [128,0,64], позадина [255,128,192];
- тиркизна: текст [0,128,128], позадина [128,255,255].

Пример 13 сегмената коришћених у експерименту је дат у Прилогу А. Читање једног сегмента текста, за једног испитаника, у даљем тексту ће се називати једно понављање. Испитивања са недовољним фокусом на приказани текст (време читања мање од 5 s) су искључена (12 покушаја), што је дало $13 \times 30 - 12 = 378$ понављања за даљу анализу.

Неколико биометријских параметара испитаника је праћено током задатка читања помоћу мултимодалног сензорског система. Вршено је праћење откуцаја срца, ЕЕГ-а, психогалванског рефлекса и праћење покрета очију. Поставка експеримента је приказана на Слици 5.



Слика 4. Приказ поставке експеримента.

Анализа приказана у дисертацији укључивала је само податке за праћење покрета очију који су током експеримента прикупљени помоћу *SMI RED-m* система (*Gaze intelligence*, Париз, Француска) и аквизиција је рађена на 60 Hz. Калибрација је спроведена у софтверу *SMI BeGaze*

3.7 (*Gaze intelligence*, Париз, Француска), а експеримент је покренут само ако је калибрација успешно спроведена. Прихватљива тачност за калибрацију и валидацију у 5 тачака била је 0,5 степени за обе осе. Свако испитивање је било адекватно окарактерисано са 3 низа података, од којих један представља x координате, други у координате погледа, а крајњи низ представља сигнал статуса догађаја (који указује на фиксације, сакаде и трептање/недостајуће податке). Из низова података су одсечени кратки сегменти са почетка и краја сигнала како би секвенца представљала само период читања, а не тражење текста пре почетка читања и лутање погледа пре преласка на следећи слајд.

Студија је спроведена у складу са Хелсиншком декларацијом, а одобрена од етичке комисије Департмана за психологију Универзитета у Нишу (огранак Српског друштва психолога), експериментални поступак бр. 9/2019 (04.09.2019).

7 Детекција дислексије применом класификације обележја

7.1 Увод

У претходним поглављима је већ наведено да детекција дислексије на основу различитих тестова језичких способности представља успостављени стандард за давање дијагнозе [26]. Напредовање технологије и истраживања је у процес успостављања дијагнозе увело различите алате попут софтверских решења и биомедицинских уређаја [91]. Један од најраспрострањенијих приступа за објективно успостављање дијагнозе дислексије је базиран на праћењу покрета очију. Дислексија се примарно повезује са поремећајем читања, а покрети очију представљају активност која је неопходна за читање приказаних садржаја [92].

У постојећим истраживањима за класификацију дислексије на основу праћења покрета очију током читања, анализиране су различите групе испитаника које су снимане различитим уређајима и са различитим експерименталним поставкама (секција 2.3). Такође се може уочити и разноликост у обележјима која су коришћена за квантификацију дислексичних тенденција у постојећим студијама. Управо ова разноликост у испитаницима и обележјима представља мотивацију за истраживање приказано у овој секцији.

У литератури не постоји студија која се бави препознавањем дислексије на основу очних покрета код испитаника чији је матерњи језик српски. Сваки језик има засебна правила читања и другачији ниво комплексности [9,13–15], а српски језик има изразито плитку ортографију, што значи да су правила конверзије графема у фонеме изразито једноставна. Из овог разлога, особе са дислексијом могу доћи до касних фаза школовања без потешкоћа које су довољно изражене да би била присутна дијагностика и терапија. Ово, међутим, не значи да током школовања нису постојале изражене потешкоће које би свакако могле бити умањене да је на време започета терапија.

Поред јасне мотивације да се спроведе истраживање за детекцију дислексије на српском језику, постоји и мотивација да се истраже могућности за развој нових обележја изведених на основу очних покрета. Постојећа обележја у литератури обухватају различите аспекте очних покрета, али се поставља питање да ли је могуће развити обележја која су робусна, интерпретабилна и која сама по себи могу направити јасну и убедљиву сепарабилност између класа. Дизајн оваквих обележја на бази података српских читача, њихово тестирање кроз обучавање класификатора машинског учења и статистичку анализу представља фокус истраживања приказаног у овој секцији.

7.2 Визуелизација података¹

Обележја која карактеришу покрете очију су осмишљена тако да квантификују одређене карактеристике које испитаник показује током експеримента. У студијама читања дислексичних и контролних испитаника коришћена су обележја која се често користе у анализи покрета очију (попут броја и трајања фиксација) али се наводе и посебно развијена обележја која су развијена са намером да се помоћу њих раздвоје група са дислексијом и контролна група (попут броја речи које су више пута биле у фокусу и вредности хистограма за трајање фиксација у оквиру региона

¹ Ово поглавље представља део истраживања публикованог у [17].

од интереса). Развој нових обележја, која ће јасно раздвојити групу са дислексијом и контролну групу, од великог је интереса, јер обележја која самостално пружају велику сепарабилност између класа могу послужити за објективну дијагностику дислексије и праћење ефеката третмана. Развој ових обележја захтева темељну евалуацију направљених снимака очних покрета, а начин приказа постојећих података може значајно олакшати процес креирања обележја.

За потребе развијања нових обележја и детаљне анализе развијен је нов метод за приказ очних покрета. Метод подразумева исцртавање тачке фокуса у $x - y$ равни (равни екрана) пратећи следећа правила:


- боја линије погледа уцртане између тачака $p_{k-1} = (x_{k-1}, y_{k-1})$ и $p_k = (x_k, y_k)$ израчунава се на основу растојања између тачака p_{k-1} и p_k , користећи мапу боја *jet* [93];
- линије се исцртавају на белој позадини;
- *jet* мапа боја покрива распон дужине линија од 0 до произвољно постављеног прага l_{max} где се параметар l_{max} бира тако да покрије распон дужина сакада, а да притом има довољно изражен контраст за кратке дужине линија;
- линије које повезују тачке погледа које припадају фиксацијама су повезане у потпуности, док су линије које спајају тачке које припадају сакадама испрекидане како би се лакше уочила разлика између ових догађаја (подела на фиксације и сакаде добијена из софтвера за аквизицију података);
- последње забележене координате погледа пре и после детектованог стања трептања су означене црвеним звездицама како би се лакше испратио број трептаја као и тренутак у коме се трептај догодио;
- прозирност линије која повезује тачке погледа се повећава током испитивања према следећој једначини:

$$prozirnost(n) = 10\% + 80\% * \min(1, n/n_{max}) \quad (2)$$

где n представља број одбирка а n_{max} представља праг након ког се прозирност више не смањује.

Параметри l_{max} и n_{max} се могу прилагодити спрам података који се анализирају, а пример приказа очних покрета у $x - y$ равни обичним исцртавањем и помоћу предложеног алгорита је дат на Слици 6. Изабрани параметри су утврђени емпиријски на нивоу целе базе података и износе $l_{max} = 200 \text{ px}$ (максимална дужина сакада у пикселима у оквиру читања једног реда текста) и $n_{max} = 2400$ (максимални број одбирака у једном читању). На Слици 6. се може уочити јасна визуелна разлика између образаца очних покрета контролног испитаника и испитаника са дислексијом и за обичан приказ (А1 и Б1 секције Слике 6.) али приказ помоћу развијене методе (А2 и Б2 секције Слике 6.) даје много јаснији увид у динамику читања. Испрекидане линије сакада омогућавају јасан увид у то где фиксације почињу и где се завршавају, црвене звездице означавају тренутке трептања, провидност линије даје илустрацију укупног трајања читања, а скала боја даје информације о брзини покрета очију. На основу овог приказа су рађене анализе образаца читања и развијана су различита обележја која су представљена у наредним секцијама. Примери развијеног приказа за све испитанике за читање текста на белој позадини су дати у Прилогу Б.

Учитавање, обрада и приказ сигнала су урађени у *Python* програмском језику, верзији 3.8.1 [94], користећи *pandas* [95], *numpy* [96] и *matplotlib* [97] библиотеке.



Слика 5. Приказ очних покрета једног испитаника са дислексијом и једног контролног испитаника у $x - y$ равни. А1 представља обичан приказ очних покрета контролног испитаника, Б1 обичан приказ очних покрета испитаника са дислексијом, А2 развијени приказ контролног испитаника и Б2 развијени приказ испитаника са дислексијом. Слика је преузета из [17] и допуњена.

7.3 Детекција дислексије на основу обележја изведених из фиксација и сакада²

7.3.1 Метода

Екстракција обележја

Из очних покрета испитаника из базе описане у секцији 6, издвојене су две групе обележја. Свако обележје се рачуна на нивоу једног понављања једног испитаника. Прва група подразумева конвенционална обележја која су коришћена у литератури и анализирана у студији током које је прикупљена коришћена база података [1]. Ова обележја укључују укупан број фиксација, укупан број сакада, фреквенција фиксација, фреквенција сакада, просечно трајање фиксација, просечно трајање сакада, укупно трајање фиксација, укупно трајање сакада и укупно време читања. Друга група обележја представља пет нових обележја која су развијена анализом визуелизованих података на којима су се могле уочити тенденције образаца очних покрета особа са дислексијом.

Уведена су три нова просторна обележја, као и два нова временска обележја. Просторна обележја су повезана са фиксацијама и не ослањају се директно на трајање фиксације или број фиксација. Уместо тога, обележја квантификују неправилности и сложености погледа током догађаја фиксације у x – y координатној равни. Прво предложено просторно обележје се назива **коэффициент самопресека фиксације** (КСФ) и рачуна се као:

$$\text{КСФ} = \frac{1}{n} \sum_{i=1}^n \text{БСФ}_i \quad (8)$$

где n представља број фиксација у понављању, а БСФ_i представља број самопресецања линија које припадају фиксацији i у x – y равни. Ово обележје је уведено зато што је уочен већи број самоукрштања линија погледа током фиксација код испитаника са дислексијом у поређењу са контролним. Друга метрика просторног обележја се назива **варијабилност самопресека фиксација** (ВСФ) и представља стандардну девијацију претходно описаног БСФ_i низа:

$$\text{ВСФ} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{БСФ}_i - \text{КСФ})^2} . \quad (9)$$

Ово обележје је уведено зато што је број самопресецања у линијама погледа током фиксација више варирао од фиксације до фиксације у оквиру једног понављања за субјекте са дислексијом у поређењу са контролним субјектима. Треће просторно обележје се назива **средња фрактална димензија фиксација** (СФДФ), а рачуна се као:

$$\text{СФДФ} = \frac{1}{n} \sum_{i=1}^n \text{ФДФ}_i \quad (10)$$

² Ово поглавље представља део истраживања публикованог у [17].

где n представља број фиксација у понављању а $ФДФ_i$ представља фракталну димензију линије фиксације i у x – у равни, естимирану на основу *box-counting* методе [98]. Ово обележје се не заснива на броју пресека исцртане линије већ на њеној комплексности и неправилности облика, која је израженија код групе са дислексијом.

Поред просторних обележја, уведена су и два временска обележја, под називом *активно време читања* и *варијабилност интерсакадних интервала* (ВИИ). *Активно време читања* се израчунава као време проведено у стању фиксација и сакада, ефективно искључујући време проведено у стању трептања или интервале у којима поглед није детектован. Ово обележје је уведено са циљем да се посматра само време проведено у активном читању приказаног текста, без интервала у којима поглед лута ван региона екрана. На крају, ВИИ је израчуната као стандардна девијација дужине временских интервала између две суседне сакаде. Увођење овог обележја је оправдано тенденцијом сакада да буду равномерније распоређене у времену код контролних субјеката, у односу на оне са дислексијом.

Након екстракције обележја, свако понављање (укупно 378 понављања) је било представљено скупом од 14 (9 конвенционалних и 5 развијених) обележја и одговарајућом ознаком класе (контролна група или група са дислексијом). Добијени скуп података је коришћен за обучавање четири алгорита машинског учења као и за извођење статистичке анализе.

Класификација и статистичка анализа

Одабрани алгоритми су логистичка регресија (енг. *logistic regression, LR*) [99], *SVM* [100], *KNN* [101] и *RF* [102]. Алгоритми су имплементирани у програмском језику *Python* верзија 3.8.1 [94], користећи библиотеку *sklearn* [103]. Приликом обучавања сваког од алгоритама, тренинг скуп је стандардизован (има средњу вредност 0 и стандардну девијацију 1), а параметри за стандардизацију на тренинг скупу су касније коришћени на тест скупу. Хиперпараметри модела су задржани на подразумеваним вредностима из библиотеке *sklearn* (осим параметра *probability* који се користи у имплементацији *SVM*) и за коришћене алгоритме су следећи:

- *LR*: функција губитка - *penalty* = l2; параметар регуларизације - $C = 1$; оптимизатор - *solver* = lbfgs; *maximum iteration number* = 100;
- *SVM*: параметар регуларизације - $C = 1$; *kernel* = rbf - *Radial Basis Function*, континуално предвиђање - *probability* = *True*;
- *KNN*: број суседа - *number of neighbors* = 5; селекција алгорита оптимизације - *algorithm* = *auto*; растојање између тачака - *distance* = *Euclidian*;
- *RF*: број естиматора - *number of estimators* = 100; критеријум за поделу - *criterion for split* = *Gini impurity*; без максималне дубине стабла - *max depth* = *None*; максималан број обележја - *max features* = *sqrt*; метода агрегације - *using bootstrap*.

Хиперпараметри модела нису мењани јер је фокус у овој фази истраживања био на развоју нових обележја и класификатори су служили само као прелиминарни показатељ потенцијала обележја да раздвоји класу са дислексијом и неуротипичну класу. Преглед алгоритама машинског учења, њихових функционалности и хиперпараметара је дат у Прилогу В.

Сваки алгоритам је обучен и евалуиран за свако појединачно обележје (1 улазни параметар); за сва конвенционална обележја (9 улазних параметара); за сва развијена обележја (5 улазних параметара); и за сва обележја (14 улазних параметара). Резиме свих 17 могућих опција улазних параметара за сваки од алгоритама је дат у Табели 7. Свака од комбинација алгорита и улазних

обележја је процењена коришћењем *subject-wise leave-one-out* унакрсне валидације. У *subject-wise leave-one-out* унакрсној валидацији, једна целина представља податке једног субјекта, тако да се у овом случају цео скуп дели на 30 целина, једна целина (подаци једног субјекта) се користи за тестирање, а осталих 29 целина (подаци 29 субјеката) се користи за обучавање алгорита. Овај процес се понавља 30 пута и вредности предикције, ознаке класа и вероватноћа предикције за сваку инстанцу тест скупа су сачувани и спојени тако да након завршетка унакрсне валидације, метрике евалуације се рачунају на свим тест скуповима заједно. Коришћене метрике евалуације су тачност (енг. *accuracy*, *ACC*); осетљивост (енг. *sensitivity*, *Se*), специфичност (енг. *specificity*, *Sp*), *F1 score* и *area under the receiver operating characteristic curve (AUROC)*. Свака од наведених метрика узима вредности од 0 до 1 (понекад изражено у процентима до 100%) и што је метрика већа, то класификатор има боље перформансе. Формуле за метрике *Se*, *Sp* и *F1 score* се могу изразити помоћу параметара *true positive (TP*, испитаници са дислексијом чија је предикција да имају дислексију), *false positive (FP*, контролни испитаници чија је предикција да су дислексични), *true negative (TN*, контролни испитаници чија је предикција да су контролни) и *false negative (FN*, испитаници са дислексијом чија је предикција да су контролни):

$$Se = TP / (TP + FN), \quad (1)$$

$$Sp = TN / (TN + FP), \quad (2)$$


$$F1\ score = TP / (TP + \frac{1}{2}(FP + FN)). \quad (3)$$

Табела 7. Преглед опција за улазне параметре у алгоритме машинског учења.

бр.	Групе обележја као улази	бр.	Појединачна обележја као улази (1 улазни параметар)
1.	Конвенционална обележја (9 улазних параметара): Укупан број фиксација, Укупно време трајања фиксација, Фреквенција фиксација, Средње време трајања фиксација, Укупан број сакада, Укупно трајање сакада, Фреквенција сакада, Средње време трајања сакада, Укупно време читања	4.	Активно време читања
		5.	Коефицијент самопресека фиксација
		6.	Варијабилност интерсакадних интервала
		7.	Варијабилност самопресека фиксација
2.	Развијена обележја (5 улазних параметара): Активно време читања, Коефицијент самопресека фиксација, Варијабилност интерсакадних интервала, Варијабилност самопресека фиксација, Средња фрактална димензија фиксација	8.	Средња фрактална димензија фиксација
		9.	Укупан број фиксација
		10.	Укупно трајање фиксација
		11.	Фреквенција фиксација
		12.	Средње време трајања фиксација
		13.	Укупан број сакада
		14.	Укупно трајање сакада
3.	Конвенционална и развијена обележја (14 улазних параметара)	15.	Фреквенција сакада
		16.	Средње време трајања сакада
		17.	Укупно време читања

Рангирање обележја је извршено како би се обележја сортирала по доприносу у погледу класификације дислексције, а засновано је на *RF* алгоритму и процени *Gini importance* параметра [104]. Статистичка анализа је затим урађена у софтверу SPSS (16.0 *IBM Corp*, Њујорк, САД) за свако од обележја за које се показало да указују на дислексичне тенденције према рангирању обележја. Прво је урађен *Mann–Whitney* тест да би се упоредиле вредности обележја за сваку конфигурацију боја засебно, између две групе испитаника (групе са дислексијом и контролне). Затим је спроведен *Levene* тест хомогености варијанси са циљем да се упореди дисперзија посматраног обележја за сваку конфигурацију боја засебно, између две групе испитаника. Завршни део статистичке анализе укључивао је *Wilcoxon* тест рангова који је спроведен у оквиру групе испитаника са дислексијом, упоређујући вредности обележја између различитих конфигурација приказа текста (боја). Ова анализа је извршена за сваки пар конфигурација како би се утврдило да ли је дата конфигурација повољнија за субјекте са дислексијом.

Приказ целокупне анализе у виду алгоритма је дат на Слици 7.



Слика 6. Алгоритамски приказ обраде и анализе података за развијање и евалуацију обележја заснованих на фиксацијама и сакадама. Слика је преузета из [17] и прилагођена.

7.3.2 Резултати и дискусија

Усредњене метрике постигнуте на скуповима за тестирање за четири алгоритма машинског учења (*LR*, *SVM*, *KNN*, *RF*), користећи три различита скупа обележја (конвенционална, развијена и сва обележја) као улазне податке, дате су у Табели 8. Остварени резултати показују високу тачност и конзистентно бољи резултат при коришћењу развијених обележја, као и свих обележја

у поређењу са само конвенционалним. Најбоља тачност и за развијена обележја и за сва обележја је добијена помоћу *LR*, и прелази за скоро 10% најбољу тачност од 85% добијену за конвенционална обележја *SVM* алгоритмом. Такође, посматрано на нивоу субјекта, 29 од 30 субјеката је тачно класификовано (када се усредње предикције за понављања једног субјекта), дајући тачност од 96,7%. Узимајући у обзир балансираност класа, у даљој дискусији се фокус приликом анализе добијених метрика поставља на тачност, али важно је напоменути да и друге метрике за евалуацију дају боље резултате за развијена обележја у односу на конвенционална. *Se* параметар, који представља способност алгоритма да детектује особе са дислексијом је 0,89 за развијена обележја, а 0,78 за конвенционална. Разлика је нешто мања за *Sp* параметар који представља способност алгоритма да неуротипичну особу заиста класификује као неуротипичну, и износи 0,98 за развијена обележја и 0,97 за конвенционална. Разлике између *F1-score* параметра су такође изражене, са 0,93 за развијена обележја и 0,83 за конвенционална, што је очекивано имајући у виду да је *F1-score* осетљив и на лажно позитивне и лажно негативне предикције, а класе су избалансиране и тачност предикције је веома висока. Слично се може рећи и за *AUROC* параметар, који достиже максимум од 0,98 за развијена обележја, а 0,89 за конвенционална.

Табела 8. Метрике за евалуацију класификације на основу различити група метрика (резултати развијених обележја су приказани *bold* текстом).

Група обележја	Алгоритам машинског учења			
	<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Конвенционална обележја				
<i>ACC</i>	0.84	0.85	0.81	0.82
<i>Se</i>	0.78	0.72	0.66	0.75
<i>Sp</i>	0.90	0.97	0.94	0.92
<i>F1 score</i>	0.83	0.82	0.77	0.81
<i>AUROC</i>	0.88	0.89	0.87	0.86
Развијена обележја				
<i>ACC</i>	0.94	0.93	0.88	0.93
<i>Se</i>	0.89	0.88	0.78	0.89
<i>Sp</i>	0.98	0.98	0.98	0.97
<i>F1 score</i>	0.93	0.93	0.86	0.93
<i>AUROC</i>	0.96	0.98	0.94	0.95
Сва обележја				
<i>ACC</i>	0.94	0.93	0.87	0.94
<i>Se</i>	0.89	0.87	0.75	0.86
<i>Sp</i>	0.98	0.98	0.98	0.97
<i>F1 score</i>	0.93	0.92	0.84	0.91
<i>AUROC</i>	0.96	0.97	0.94	0.94

Просечна тачност добијена на скупу за тестирање постигнута када се свако појединачно обележје користи као улаз за алгоритме машинског учења је приказана у Табели 9. Остале метрике

за процену засебних обележја су представљене у Прилогу Г. Најбоља тачност је постигнута за варијабилност самопресека фиксација. Друга и трећа по рангу тачност постигнуте су за коефицијент самопресека фиксација и средњу фракталну димензију фиксација. Тачности постигнуте за ова три обележја и за све алгоритме машинског учења биле су веће од тачности постигнутих када се користе сва конвенционална обележја као улазни подаци.

Табела 9. Просечна тачност добијена на скупу за тестирање за појединачна обележја.


	Обележје	Алгоритам машинског учења			
		<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Развијена обележја	Активно време читања	0.78	0.75	0.74	0.76
	Коефицијент самопресека фиксација	0.90	0.90	0.89	0.89
	Варијабилност интерсакадних интервала	0.74	0.74	0.76	0.73
	Варијабилност самопресека фиксација	0.91	0.90	0.91	0.91
	Средња фрактална димензија фиксација	0.89	0.90	0.89	0.89
Конвенционална обележја	Укупан број фиксација	0.84	0.85	0.84	0.84
	Укупно трајање фиксација	0.78	0.74	0.77	0.76
	Фреквенција фиксација	0.35	0.30	0.52	0.63
	Средње време трајања фиксација	0.46	0.49	0.48	0.63
	Укупан број сакада	0.81	0.81	0.83	0.82
	Укупно трајање сакада	0.78	0.74	0.76	0.76
	Фреквенција сакада	0.57	0.47	0.63	0.57
	Средње време трајања сакада	0.48	0.56	0.60	0.56
	Укупно време читања	0.80	0.77	0.74	0.75

Урађено је и рангирање значаја сваког појединачног обележја, а резултати су приказани на Слици 8. Рангирање значаја обележја указује да три развијена просторна обележја (коефицијент самопресека фиксација, средња фрактална димензија фиксација и варијабилност самопресека фиксација) која су постигле највећу индивидуалну тачност класификације заиста доприносе високој прецизности класификације када се посматрају као део скупа обележја. Имајући то у виду, та три обележја су коришћене за даљу статистичку анализу.

Boxplot прикази коефицијента самопресека фиксација, средње фракталне димензије фиксација и варијабилности самопресека фиксација за сваку конфигурацију боја и сваку групу испитаника (група са дислексијом и контролна група) приказани су на Слици 9.


Boxplot дијаграми показују да постоји јасна разлика између класе са дислексијом и контролне класе за сваку конфигурацију боја (контролна група има много ниже вредности обележја од групе

са дислексијом). То је додатно показано и статистичком анализом. За три најважнија обележја, за сваку конфигурацију боја, постигнута је статистички значајна разлика између група испитаника ($p < 0,001$) коришћењем *Mann–Whitney* теста. Такође, Левенов тест распршености између група испитаника је такође показао статистички значајну разлику за свако од три обележја просторне сложености фиксације (коефицијент самопресека фиксација, средња фрактална димензија фиксација и варијабилност самопресека фиксација) за сваку конфигурацију боје ($p < 0,01$). *Mann–Whitney* тест показује да се вредности обележја значајно разликују између група, а *Leven* тест распршености показује да за сваку конфигурацију боја, група са дислексијом има много више распршених вредности од контролне групе.




Слика 7. Рангирање значаја обележја за потребе класификације дислексије засновано на *Gini importance* параметру *RF* алгоритма. Слика је преузета из [17] и прилагођена.

Како би се утврдило да ли постоји боја/конфигурација боја која је имала позитивнији утицај на испитанике са дислексијом (боја/конфигурација која би дала најниже вредности обележја, које би биле ближе вредностима контролне групе), урађена је статистичка анализа у оквиру групе испитаника са дислексијом, упоређујући сваки пар конфигурација боја. *Wilcoxon* тест рангова је показао да постоји статистички значајна разлика ($p < 0,01$) само за три пара конфигурација боја и само за једно обележје (фрактална димензија фиксације): (1) жути *overlay* и наранџасти *overlay*, (2) наранџаста позадина и жута позадина, и (3) тиркизна позадина и жута позадина. Визуелизација конфигурационих парова за које постоји статистички значајна разлика, као и за три произвољне конфигурације за које није било значајне разлике, приказана је на Слици 10.



Слика 8. Прикази (А) коефицијента самопресека фиксација, (Б) варијабилности самопресека фиксација, (В) средње фракталне димензије фиксација за сваку конфигурацију боја и две групе субјеката. Слика је преузета из [17] и прилагођена.

Средња фрактална димензија фиксација



Слика 9. Визуелни приказ података за све субјекте са дислексијом, за три конфигурације боја које (А) показују статистички значајну разлику и (Б) не показују статистичку разлику. Испуњене тачке представљају конфигурације боја позадине, а кругови представљају *overlay* конфигурације боја. Слика преузета из [17] и прилагођена.

Сprovedена статистичка анализа и обучавање алгоритама машинског учења су дали обећавајуће резултате показујући да се помоћу развијених обележја могу раздвојити група са дислексијом и контролна група. Ови резултати су од посебног значаја зато што је матерњи језик испитаника и језик који се користи у експерименту српски, који има савршено подударње између графема и фонема. Откривање дислексије у таквим језицима (са плитким ортографским системом) је често прилично тешко; тачност од 94% постигнута на балансираном скупу података који се користи у овом раду (*F1 score* 0,93 и *AUROC* 0,96) (Табела 8) показује обећавајући резултат који је упоредив са онима постигнутим у литератури [9,11–16,72,77] који су изведени на језицима са дубљим ортографским системима. Како српски језик има плитак ортографски систем, што отежава дијагностиковање дислексије, група посматраних испитаника се може сматрати релевантном за потребе спроведеног истраживања за језик као што је српски.

Три најзначајнија обележја (коефицијент самопресека фиксација, средња фрактална димензија фиксација и варијабилност самопресека фиксација, Слика 8) која описују просторну комплексност погледа током фиксација постигле су високу тачност (89% или више, Табела 9), чак и када су коришћене као једини улаз за алгоритме машинског учења. Дизајн обележја и интерпретација података показала се као адекватан приступ пошто је једно просторно обележје које описује

комплексност фиксационог погледа постигло бољу тачност (91% за коефицијент пресека фиксације) од свих посматраних конвенционалних обележја заједно (85%). Важно је напоменути да обележја сложености фиксације јасно имају ниже вредности за контролне субјекте и више вредности за оне са дислексијом. Обележја која описују сложености фиксације, а самим тим и сложеност обрасца погледа, могу се стога сматрати индикацијом потешкоћа у читању које се могу приметити код особа са дислексијом.

Предложена обележја такође могу имати примену у анализи дислексије за језике поред српског, јер проблем фокусирања на речи може довести до сличних хаотичних покрета фиксација у другим језицима. Недостатак ових обележја је у томе што захтевају одређену фреквенцију узорковања и просторну прецизност праћења очију, јер се развијена карактеризација фиксација ослања на анализу финих покрета очију. Видно поље читача такође може утицати на квалитет обележја јер читање са веће/краће удаљености од екрана/папира може омогућити читаоцу да има различит број речи унутар једне тачке фокуса. Ова појава може учинити хаотично кретање погледа или тежим за откривање или ближим сакадама, што би могло утицати на сепарабилност класа.

Статистичка анализа је показала да просторна обележја обезбеђују јасну сепарабилност класа без обзира на конфигурацију боја, као што је приказано на Слици 9. Статистичке разлике између група субјеката за све конфигурације боја показују да се не постоји једна конкретна боја која се може користити за олакшавање читања у тој мери да се вредности обележја групе са дислексијом и контролне групе приближе.

Поређење између конфигурација боја за субјекте са дислексијом показује да могу постојати конфигурације боја које су повољније од других. Анализа унутар групе са дислексијом је такође показала статистички значајну разлику између само три пара конфигурација, као што се види на Слици 10, што указује да ниједна боја, универзално, не чини читање лакшим или тежим у поређењу са другим бојама. Недостатак доследно супериорне конфигурације, међутим, указује да боје имају различит ефекат на сваког субјекта и да би, како би се деци са дислексијом олакшало читање, персонализован приступ највероватније био најбоље решење. До истог закључка се могло доћи посматрањем статистичке анализе између група испитаника, пошто је статистички значајна разлика била истакнута за сваку конфигурацију боја, што указује да се ниједна боја не истиче у смислу да особе са дислексијом и контролни субјекти буду сличнији у својим обрасцима читања.

7.3.3 Закључак

У овом поглављу је представљен нови скуп просторно-временских обележја за препознавање образаца погледа код испитаника са дислексијом чији је матерњи језик српски. Предложени скуп обележја показао је значајно побољшање класификације у поређењу са конвенционалним обележјима за праћење очију (94% наспрам 85%). Статистичка анализа између група испитаника (група са дислексијом и контролна група) показала је високу сепарабилност класа, независно од конфигурације боја. Статистичка анализа у вези са утицајем боје на перформансе читања обављена је унутар групе испитаника са дислексијом и показала је високу интерсубјектну варијабилност.

Главна ограничења описаног истраживања су број учесника и употреба високопрецизног система за праћење покрета очију. Међутим, добијени резултати представљају значајан искорак у области детекције дислексије, а даљи рад би могао да обухвати увођење обележја мерених другим сензорским системима (укључујући и *low-cost* системе), анализу већег броја испитаника, или базу података са широм старосном расподелом. Анализа података са различитих уређаја за праћење

покрета очију и комбиновање добијеног скупа података са другим скуповима података (потенцијално на различитим језицима) такође може бити део будућих истраживања.

7.4 Детекција дислексије у реалном времену³

7.4.1 Метода

Екстракција обележја


Сегментација очних покрета на сакаде и фиксације представља проблем које нема једнозначно решење и има више различитих приступа који се могу користити [71]. Разлике у овим алгоритмима могу резултовати другачијим поделама на фиксације и сакаде, што може утицати на обележја која се на основу њих креирају. Како се у студијама дислексије најчешће користе обележја управо заснована на фиксацијама и сакадама, циљ истраживања описаног у овом поглављу је развој обележја која ће бити робусна и независна од поделе сигнала очних покрета на фиксације и сакаде.

Процес екстракције обележја је осмишљен тако да се ослања само на редослед x и y у координата погледа, без информација о догађајима фиксација и сакада. Као први корак су уклоњене тачке које нису имале информације о координатама погледа за оба ока, остављајући само податке где је поглед могао да се лоцира на екрану (просечан проценат података за једно понављање који није садржао координате погледа био је 4,5% од укупног броја података за групу са дислексијом и 2,5% за неуротипичну групу). Други корак подразумева увођење две различите методе за издвајање обележја. Ове методе су примењене како би се откриле потешкоће испитаника током читања и добијена обележја су означена као Обележје 1 и Обележје 2.

Обележје 1 је засновано на детекцији самопресецања (СП) линија погледа током читања. Посматрају се сваке четири узастопне тачке података у x -у координатној равни и проверава се да ли линија погледа која повезује ове тачке има СП. Ако постоји пресек, број промена у смеру кретања погледа на y -оси се прати у наредних 250 ms (приближно просечно трајања фиксације [105]). Свака промена се броји, а резултат броја вертикалних промена (БВП)—који указује на број промена у смеру кретања на y -оси додаје се укупном БВП-у Обележја 1. Дакле, Обележје 1 почиње од вредности 0 на почетку понављања, и сваки пут када се СП открије у четири узастопне тачке података, функција се може повећати на основу БВП -а у временском периоду који следи детекцију СП. Ово ефективно узрокује да вредност Обележја 1 прогресивно расте током испитивања, али користи СП као вид тригера, а БВП посматраних временских интервала као квантификацију потешкоћа током читања.

Обележје 2 прати исти принцип као и Обележје 1, али уместо да користи СП линије четири узастопне тачке података као тригер за увећање БВП-а, користи број промена у смеру погледа на y -оси четири узастопне тачке података (посматрање БВП-а у четири узастопне тачке података). Ако постоје две промене у смеру кретања на y -оси у четири посматране узастопне тачке података, БВП погледа добијен у оквиру од 250 ms након догађаја окидача додаје се укупном БВП-у Обележја 2. Пример Обележја 1 и Обележја 2 издвојених за читање једног реда текста за испитаника са дислексијом је дат на Слици 11.

³ Ово поглавље представља резултате истраживања публикованог у [19].




Слика 10. Обележје 1—детекција СП-а и Обележје 2— детекција БВП-а за испитаника са дислексijом, са линијама погледа које одговарају догађајима окидача обојеним црвеном бојом.. Слика је преузета из [19] и прилагођена.

Слика 11 јасно показује много већи број тригера у Обележју 2, изазвано тиме што је промена смера кретања по у оси много чешћа од СП у четири узастопне тачке. Сходно томе Обележје 2 ће имати много веће вредности од Обележја 1, детектујући више тригера и самим тим имаће више

могућности да се повећа на основу БВП-а у посматраном временском интервалу од 250 ms. Пример Обележја 1 и Обележја 2 за један ред текста за контролног испитаника је дат на Слици 12.

Пример обрасца читања контролног испитаника



Слика 11. Обележје 1—детекција СП-а и Обележје 2— детекција БВП-а за контролног испитаника, са линијама погледа које одговарају догађајима окидача обојеним црвеном бојом. Слика је преузета из [19] и прилагођена.

За разлику од испитаника са дислексијом, контролни испитаник има мањи број тригера и укупне ниже вредности обележја. БВП није близу 0, посебно када се тригер заснива на детекцији БВП-а у четири узастопне тачке, јер вертикалне промене у кретању погледа саме по себи не указују на образац читања особе са дислексијом, али број промена након тригера се очекује да ће бити нижи код контролне групе јер испитаници са дислексијом имају просторно сложенији образац погледа.

Да би се истражила стабилност предложених обележја и могућност њиховог коришћења са подацима добијеним са нижом фреквенцијом одабирања, процес екстракције обележја је поновљен на координатама са фреквенцијом одабирања смањеном са 60 Hz на 30 Hz. Ово даје укупно четири посматрана обележја: Обележје 1 на 60 Hz, Обележје 1 на 30 Hz, Обележје 2 на 60 Hz и Обележје 2 на 30 Hz. Свако од обележја је анализирано независно као улаз за различите алгоритме машинског учења, као и кроз статистичку анализу.

Поред тога, укупно време читања сваког испитивања коришћено је као улаз у алгоритме машинског учења као референтно обележје за класификацију дислексије.

Класификација и статистичка анализа

Имплементирани алгоритми машинског учења су *LR*, *SVM*, *KNN* и *RF*, а метрике које су коришћене су *ACC*, *Se*, *Sp*, *F1 score* и *AUROC*. Евалуација је урађена користећи *subject-wise leave-one-out* унакрсну валидацију како би се добили резултати који би били слични онима у пракси, узимајући све податке од једног субјекта и користећи их као тест скуп, а остатак података користећи као тренинг скуп. Овај поступак је поновљен 30 пута (подаци сваког испитаника су тачно једном били у тест скупу), а предикције алгоритама и лателе података из свих тест скупова су спојени и коришћени за рачунање метрика класификације. На сваком тренинг скупу урађен је *grid-search* за оптимизацију хиперпараметара користећи петоструку унакрсну валидацију, и најбољи хиперпараметри за дати алгоритам су искоришћени за обучавање на целом тренинг скупу и креирање предикција на тест скупу.

Статистичка анализа података подразумева поређење групе са дислексијом и контролне групе на свим конфигурацијама боја заједно, и за сваку конфигурацију боја посебно, користећи *Mann–Whitney* статистички тест. Анализа утицаја сваке конфигурације боја на групу са дислексијом је извршена упоређивањем сваког пара конфигурације боја унутар групе са дислексијом, такође користећи *Mann–Whitney* тест. Ефекат боја на сепарабилност класа је такође анализирана приказивањем *boxplot*-а за свако обележје за групу са дислексијом и контролну групу када је сваки од појединаца процењен на основу конфигурације боја са најбољим учинком (најмање вредности Обележја 1 и 2) и конфигурације боја са најгорим учинком (највеће вредности Обележја 1 и 2).

Обрада података, имплементација алгоритама машинског учења, статистичка анализа и визуелизација података су урађени у *Python* програмском језику, верзији 3.8.1 [94], користећи *pandas* [95], *numpy* [96], *sklearn* [103] и *matplotlib* [97] библиотеке.

7.4.2 Резултати и дискусија

Резултати извршене унакрсне валидације за свако обележје и за све посматране алгоритме машинског учења су приказани у Табели 10.

Табела 10. Метрике евалуације на тест скупу за свако обележје и за све алгоритме машинског учења.


Обележје/Фреквенција	Алгоритам машинског учења			
	<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Обележје 1 – детекција СП/60 Hz				
<i>ACC</i>	0.870	0.878	0.865	0.868
<i>Se</i>	0.822	0.822	0.822	0.822
<i>Sp</i>	0.917	0.933	0.907	0.912
<i>F1 score</i>	0.861	0.869	0.856	0.859
<i>AUROC</i>	0.869	0.877	0.864	0.867
Обележје 1 – детекција СП/30 Hz				
<i>ACC</i>	0.860	0.860	0.831	0.823
<i>Se</i>	0.811	0.805	0.795	0.795
<i>Sp</i>	0.907	0.912	0.965	0.850
<i>F1 score</i>	0.850	0.849	0.821	0.814
<i>AUROC</i>	0.859	0.859	0.830	0.822
Обележје 2 – детекција БВП/60 Hz				
<i>ACC</i>	0.889	0.889	0.881	0.881
<i>Se</i>	0.849	0.854	0.859	0.859
<i>Sp</i>	0.927	0.922	0.902	0.902
<i>F1 score</i>	0.882	0.883	0.876	0.876
<i>AUROC</i>	0.888	0.888	0.881	0.881
Обележје 2 – детекција БВП/30 Hz				
<i>ACC</i>	0.878	0.860	0.862	0.860
<i>Se</i>	0.859	0.816	0.827	0.827
<i>Sp</i>	0.896	0.902	0.896	0.891
<i>F1 score</i>	0.874	0.851	0.855	0.852
<i>AUROC</i>	0.878	0.859	0.862	0.859
Укупно време читања				
<i>ACC</i>	0.769	0.796	0.746	0.738
<i>Se</i>	0.654	0.605	0.622	0.589
<i>Sp</i>	0.860	0.974	0.865	0.834
<i>F1 score</i>	0.727	0.742	0.706	0.674
<i>AUROC</i>	0.790	0.675	0.758	0.733

Резултати евалуације дају неколико важних закључака. Без обзира на алгоритам машинског учења и развијена обележја која се користе као улазни параметри, тачност класификације је изнад 82%, што указује да су обележја у целини ефикасна у раздвајању групе са дислексијом и контролне групе. Резултати такође показују побољшане перформансе у поређењу са референтним обележјем (укупно време читања). Најбољи резултати, у смислу тачности, су добијени за Обележје 2 (детекција БВП тригера) на 60 Hz и за *LR* и *SVM*, са 88,9%. Тачности добијене за обележја добијена на основу сигнала са 30 Hz нису много ниже од вредности добијених за обележја добијена на 60 Hz, при чему је најбољи резултат тачности од 87,8% за Обележје 2 (детекција БВП тригера) и *LR* алгоритам. Ова вредност је такође једнака најбоље добијеној тачности за Обележје 1 (детекција СП тригера), дајући благу предност БВП детекцији у перформансама класификације.


Резултати статистичке анализе су у складу са целокупним резултатима класификације. Постоји статистички значајна разлика ($p < 0,001$) између групе са дислексијом и контролне групе када се све конфигурације боја посматрају заједно, за свако обележје, на обе фреквенције. Када се упореде дислексична и контролна група на свакој конфигурацији боја посебно, постоји статистички значајна разлика ($p < 0,001$) на свакој конфигурацији.

Поређење конфигурација боја унутар групе са дислексијом није показало статистички значајне разлике ни за један пар конфигурација. То, међутим, не значи да је утицај боје занемарљив, већ само да не постоји ниједна конфигурација која је универзално боља од осталих. Утицај конфигурације боје се може видети на Слици 13 за Обележје 1 и на Слици 14 за Обележје 2, и на 30 Hz и на 60 Hz. Утицај конфигурације боја је разматран тако што је у оквиру сваке групе испитаник процењен на основу конфигурације која највише олакшава читање (мала вредност обележја) и која највише отежава читање (већа вредност обележја). На приказима су упарена група са дислексијом на најбољим обележјима и контролна са најгорим, као и група са дислексијом са најгорим обележјима и контролна са најбољим. На овај начин је анализирано у којој мери се варирањем конфигурација боја могу приближити односно раздвојити две групе испитаника.

Када се посматра добијена тачност класификације, она не прелази 90%, што је забележено у неколико студија попут [13,16], али зато спада у опсег тачности (80% до 96,6% [9,13–16]) који су уобичајени за откривање дислексије на основу праћења покрета очију током читања. Резултати описани у претходној секцији дају тачност од 94% која је добијена употребом комбинације развијених обележја. Међутим, када се посматра само једно обележје, најбоља тачност је била 91% (што је 2% више од резултата добијених на основу обележја описаних у овој секцији). Коришћење једног обележја је важан циљ у контексту приступачног откривања и праћења дислексије, јер је пружање једноставне повратне информације и квантитативне мере дислексичних тенденција лакше на скали коју чини само једно обележје. Штавише, обележја предложена у претходној секцији уводе концепт просторних карактеристика погледа, али се ослањају на рашчлањивање погледа на фиксације и сакаде, што је уобичајено у литератури, али може додатно утицати на вредности обележја добијених са различитих уређаја и коришћењем различитих софтвера. Још један важан аспект Обележја 1 и Обележја 2 је да имају тригере и континуирану промену вредности, што омогућава повратне информације у реалном времену, а и могућност да се прате локације у тексту на којима се обележје значајно увећало – региони где је испитаник имао потешкоће у читању.



Слика 12. *Boxplot* прикази Обележја 1 за максимално раздвојене групе (контролни испитаници оцењени својим најбољим, а испитаници са дислексијом најгорим конфигурацијама) и приближене групе (контролни испитаници оцењени својим најгорим, а испитаници са дислексијом најбољим конфигурацијама). Слика је преузета из [19] и прилагођена.



Слика 13. *Boxplot* прикази Обележја 2 за максимално раздвојене групе (контролни испитаници оцењени својим најбољим, а испитаници са дислексијом најгорим конфигурацијама) и приближене групе (контролни испитаници оцењени својим најгорим, а испитаници са дислексијом најбољим конфигурацијама). Слика је преузета из [19] и прилагођена.

Екстракција обележја је извршена на *Intel(R) Core(TM) i3-7100 CPU @ 3.90 GHz* процесору са 16 GB RAM меморије. Количник укупног времена потребног за екстракцију обележја и укупног времена читања свих субјеката је 7,21% за Обележје 1 и 7,33% за Обележје 2 на 60 Hz. Ефективно, то значи да је за 1 s времена читања потребно ≈ 7 ms времена обраде, што омогућава обраду и повратне информације у реалном времену. Време обраде је преполовљено за екстракцију обележја на подацима добијеним на 30 Hz.

Предложена обележја ослањају се на просторне карактеристике, за које се показало да указују на дислексичне феномене у различитим језицима [18]. Обележје 1, које се ослања на детекцију СП у погледу за тригер, уведена је као мера која би била прилично рестриктивна за тригер увећања обележја, јер захтева одређену просторну резолуцију уређаја за праћење ока да би се СП детектовао. С друге стране, Обележје 2 се фокусира само на детекцију промена правца кретања на у (вертикалној) оси. Ово је много мање рестриктивно у поређењу са детекцијом СП, а промене у смеру кретања се често могу јавити и код субјеката са дислексијом и код контролних субјеката. Имајући ово у виду, велики број ових промена би се могао сматрати сложенијим просторним обрасцем, а циљ је био да се анализира како би се ове два обележја упоредо показала у детекцији дислексије.

Оба обележја предложена у овој секцији су се показала као ефикасна у раздвајању групе са дислексијом и контролне групе и показала су се ефикасним (најбоља тачност од 87,8%) када се примењују на фреквенцији одабирања од 30 Hz. Не постоје јасни закључци у смислу утицаја ниже фреквенције одабирања на класификацију у студијама описаним у литератури, али је важно напоменути да су све фреквенције одабирања из постојећих студија изнад 30 Hz: 50 Hz у [15], 60 Hz у [13], 100 Hz у [9], 200 Hz у [9] и 1000 Hz у [12]. Узимајући у обзир напредак компјутерске визије и могућности праћења очију на основу веб камера [106–108], постигнути резултати могу имати значајан допринос и послужити као будуће смернице у развоју приступачнијих система за детекцију и праћење дислексије на основу анализе покрета очију.

Обележја су осмишљена на такав начин да сваки детектовани тригер има квантитативни допринос укупној БВП вредности. Већа укупна БВП вредност указује да читалац има више потешкоћа, па се, последично, тригери (који се могу лоцирати у тексту) са већим доприносом укупној БВП вредности могу сматрати тачкама у којима је испитаник имао потешкоћа или барем регионом у тексту који је изазвао израженије дислексичне обрасце. Предложена обележја имају потенцијал за идентификацију локација у тексту где се потешкоће у читању визуелно манифестују.

Када се разматра доступност и приступачност детекције дислексије, дизајн скрининга може бити веома релевантан. Резултати приказани на Слици 13. показују утицај селекције конфигурације боје на сепарабилност групе са дислексијом и контролне групе за Обележје 1. Групе скоро да немају преклапања у вредностима обележја када су максимално раздвојене док су распони вредности много ближи и имају значајан ниво преклапања када су групе приближене. Приказани сценарији свакако представљају екстремне случајеве који се не дешавају у пракси и служе као показатељ утицаја конфигурације боја за приказ текста на сепарабилност класа. Кружни графикони испод сваког *boxplot* приказа такође показују различите конфигурације боја, што указује да се ниједна боја не може универзално издвојити у контексту олакшавања читања и да расподела конфигурација може варирати у зависности од фреквенције одабирања.

Овај закључак је додатно подржан утицајем конфигурације боја приказаног за Обележје 2, који је приказан на Слици 14. Значајано је да, иако су тригер детекције БВП и детекције СП концептуално сличне, оне показују извесне разлике у најбољој/најгорој конфигурацији боја за групу са дислексијом и контролну групу. На пример, бела позадина је прилично истакнута за оба

обележја као најбоља конфигурација за контролне субјекте на 60 Hz. С друге стране, на 30 Hz, бела позадина је присутна као најбоља конфигурација за контроле за Обележје 1, али скоро и да није присутна у расподели за најбоље конфигурације контрола за Обележје 2. Ова појава истиче важност поновљених евалуација сваке конфигурације боја, као и коришћења више различитих обележја, јер она могу представљати различите обрасце читања. Иако оба обележја ефикасно раздвајају групу са дислексијом и контролну групу, она неће нужно бити потпуно подударна када је у питању најбољи начин представљања текста.

Слике 13. и 14. визуелно показују да конфигурација боја утиче на вредности обележја. Одговарајући избор конфигурације боја може повећати или смањити вредности обележја, односно у зависности од избора боја, група са дислексијом може бити ближа или удаљенија од неуротипичне (Слика 13. и Слика 14. представљају само екстремне случајеве избора конфигурације боја). Овај закључак о реакцији појединца на боје могао би бити користан не толико за саму класификацију испитаника, колико за планирање третмана за особе са дислексијом користећи модификације текста и боје. Поред тога, кружни дијаграми на Сликама 13. и 14. показују значај персонализованог приступа у избору конфигурације боја.

Добијени резултати показују да не постоји универзално олакшавајућа или отежавајућа конфигурација за излагање текста, ни за контролну групу ни за групу са дислексијом. Међутим, када се испитаницима пружи прилика да читају текстове на њиховим најбољим/најгорим конфигурацијама, може се значајно утицати на сепарабилност класа. Ови закључци су у складу са онима из литературе [85] у погледу значаја одабране методе презентације текста и наглашавају важност евалуације испитаника коришћењем различитих сценарија у циљу добијања тачне дијагнозе.

7.4.3 Закључак

У секцији су уведена два нова обележја за праћење покрета очију која су коришћена за разликовање групе са дислексијом и контролне групе. Обележја су осмишљена имајући на уму интерпретабилност и робусност, и примењене су само на основу x и y координата погледа. Екстракција обележја је спроведена из оригиналних података (60 Hz), али и из података са смањеном фреквенцијом одабирања (30 Hz). Обележја су коришћена као улазни подаци за различите алгоритме машинског учења за класификацију дислексије и добијена је тачност од 88,9% за 60 Hz, односно 87,8% за 30 Hz. Урађена је и статистичка анализа која је показала да су обележја била ефикасна у раздвајању група на свакој конфигурацији боја, али да ниједна конфигурација није универзално боља у односу на друге. Интерпретабилност, ефикасност рачунања и робусност ових обележја у контексту фреквенције одабирања дају им велики потенцијал за приступачан скрининг дислексије, посебно зато што се фокусирају на просторне карактеристике погледа, за које се показало да могу указати на дислексичке обрасце читања на различитим језицима. Будући рад би укључивао имплементацију обележја на већем скупу података, другачији сценарио експеримента који укључује читање дужег текста укључујући визуелне ефекте гужве и анализу покрета очију на различитим језицима, као и коришћење развијених обележја са *low-cost* уређајима за праћење покрета очију који су засновани на веб камерама. Показани резултати такође указују на потенцијал примене развијених обележја за детекцију дислексичних образаца у реалном времену.

8 Детекција дислексије применом конволуционих неуралних мрежа

8.1 Увод


Поред евалуације помоћу обележја, што је најзступљенији метод у студијама за праћење покрета очију, постоје и приступи који се заснивају на раду са сировим или обрађеним сигнаlima, али без издвајања обележја. Овакав приступ је омогућен развитком различитих алгоритама вештачке интелигенције, а једна област која је доживела највећу експанзију је примена неуралних мрежа. Иако постоје различите студије које користе неуралне мреже за анализу покрета очију [109–111], и различите студије које користе неуралне мреже за предикцију дислексије на основу обележја [112] или анализе снимака магнетне резонанце [113], само једна студија у литератури користи неуралне мреже како би детектовала дислексичне тенденције из сигнала очних покрета [16]. Ова студија користи податке прикупљене у [9] и користи једнодимензионе конволуционе неуралне мреже да класификује сигнале испитаника у групу са дислексијом или неуротипичну групу. Као улаз у неуралне мреже се узимају секвенце x и y координата у времену након неколико различитих типова модификација, како би сви улази у мреже имали исте димензије. Постигнута тачност од 96,6% иде у прилог томе да конволуционе неуралне мреже могу са великим степеном поузданости детектовати дислексичне обрасце током читања у снимцима очних покрета, отварајући могућности за даља истраживања и примену конволуционих неуралних мрежа за успостављање дијагнозе дислексије.

Конволуционе неуралне мреже представљају посебну врсту неуралних мрежа, и пронашле су широку примену у великом броју области [114]. Конволуционе неуралне мреже имају неуроне који функционишу по принципу кернела и конволуције [115]. Типична дводимензионална конволуциона мрежа која се користи за анализу слике се састоји из барем два различита типа слојева. Један тип слоја представља конволуциони слој. Конволуциони слојеви се састоје из неурона који су груписани у кернеле и ти кернели се крећу кроз слику (или кроз излаз из претходног слоја) и дају одређени број излаза за даље слојеве. Излази се рачунају применом множења тежина кернела са посматраним улазом и применом одговарајуће активационе функције. Тежине кернела се адаптирају током процеса обучавања и могу се сматрати „интелигенцијом“ конволуционе неуралне мреже. Други тип слојева који се углавном налази у конволуционим неуралним мрежама представља такозване *pooling* слојеве. Ови слојеви немају тежине које се мењају током процеса обучавања већ само служе за смањење димензионалности излаза из претходног слоја. Смањење димензионалности се обично ради тако што се прозор одређене величине и са одређеним кораком шета кроз излазе из претходног слоја, и за сваку локацију се извуче просечна или максимална вредност. На овај начин се неколико пута може смањити број излаза из претходног слоја, а *pooling* се користи како би се омогућило издвајање и долажење до изражаја само најзначајнијих елемената. Конволуционе неуралне мреже често имају и *dropout* слојеве и слојеве за нормализацију. *Dropout* слојеви служе како би се спречило преобучавање, док слојеви за нормализацију чине да излази неурона буду ближи гаусовим расподелама и на тај начин олакшавају процес обучавања. На крају мреже, након конволуционих слојева, често се може наћи неколико *fully connected* слојева неуралне мреже, јер се конволуциони део може сматрати заменом за издвајање обележја, а затим *fully connected* део мапира та обележја на жељене излазе. Различити типови слојева у конволуционим неуралним мрежама, њихов одабир, интерпретација и

математичка позадина су честа тема у модерним истраживањима и детаљније информације о сваком појединачном аспектима се могу пронаћи у релевантној литератури [116–119].

Као једна од многобројних архитектура конволуционих неуралних мрежа која је пронашла своју примену у области обраде слике може се издвојити конволуциони аутоенкодер. Овај тип архитектуре користи принцип конволуције као и стандардна конволуциона неурална мрежа, али има фундаментално другачији циљ. Ако се узме да стандардна дводимензионална конволуциона неурална мрежа служи за класификацију (предикцију вредности дискретног скупа) или регресију (предикцију вредности континуалног скупа) конволуциони аутоенкодер на свом излазу не ради стандардну класификацију или регресију већ као циљ предикције има слику.

На Слици 15. се може видети пример структуре дводимензионалне конволуционе неуралне мреже и дводимензионалног конволуционог аутоенкодера за класификацију.



Слика 14. Илустрација архитектура конволуционе неуралне мреже за класификацију и конволуционог аутоенкодера. Плавом бојом су означени примери локација конволуционих кернала док црвена боја означава прелазак излаза кернала у следећи слој неуралне мреже.

На Слици 15. се може видети да конволуциона неурална мрежа има два дела, од којих први чине конволуциони слојеви, а други *fully connected* слојеви са тиме да излаз из овакве мреже обично представља коначан број скаларних вредности које нису нужно повезане. У случају конволуционог аутоенкодера, архитектура има две целине које се могу издвојити: енкодер и декодер. Енкодер сажима улазну слику у компримовани простор обележја, а затим декодер на основу тих обележја реконструише улазну слику. Дакле, у својој основној намени, аутоенкодер на

улазу и излазу има исту слику, коју покушава да сажме у компримовани простор обележја и да је затим реконструише. У овом контексту, једна од примена конволуционих аутоенкодера која је од интереса за методе представљене у овом поглављу је детекција аномалија [120]. Аутоенкодери откривају аномалије у подацима јер имају тенденцију да након обучавања реконструишу „типичне“ или више заступљене податке боље од података који имају сложенији или другачији образац. Важно је напоменути, да поред детекције аномалија, аутоенкодери имају многе друге примене, и не морају нужно реконструисати исту слику са улаза мреже на излазу, већ се могу користити да је модификују, побољшају или да ураде неки други вид трансформације [121–124].

8.2 Детекција дислексије помоћу VGG16 мреже⁴

8.2.1 Метода


Претпроцесирање

Иницијални корак у примени дводимензионалних конволуционих неуралних мрежа на сигнале очних покрета је трансформација очних покрета у дводимензионални приказ. Анализа описана у овој секцији је рађена на основу базе података описане у шестом поглављу, која садржи 378 инстанци од 30 различитих испитаника, 15 са дислексијом и 15 неуротипичних. Блок дијаграм примењеног алгорита се налази на Слици 16.

Конверзија секвенци x и y у координата погледа у слике је урађена у три корака: чишћење сигнала, дељење сигнала на сегменте и исцртавање. У првом кораку су избачени сви тренуци у којима не постоје подаци о координатама оба ока. Затим је свако понављање подељено на n делова. Ова подела је мотивисана циљем да се увећа број инстанци на којима се конволуционе мреже обучавају, али и да се омогући неуралној мрежи да анализира детаље кретања ока, као и да се истражи утицај овог параметра на перформансе неуралне мреже. Три различите вредности параметра n су разматране, $n = 3$, $n = 5$ и $n = 10$. Свака од инстанци података добијених кроз поделу понављања је визуелизована у дводимензионалној равни која показује траг погледа испитаника у том одређеном временском прозору.


Посматрана инстанца је исцртана коришћењем кодирања боја, приступом који је сличан ономе описаним у поглављу 7.2 али уз одређена поједностављења. Принцип бојења линија које спајају узастопне тачке је исти као у опису секције 7.2 али је све исцртано пуном линијом и нема назначених тренутака трептаја, а прозирност је константна и постављена на 60%. Ова поједностављења су уведена узимајући у обзир две ставке. Прва је да конволуционе неуралне мреже дати приказ посматрају као слику тј. као матрицу пиксела, тако да би непрекидане линије, звездице и повећање провидности унеле „шум“ за који је неизвесно да ли би релативно мала неурална мрежа са релативно малим бројем доступних података успела да растумачи на прави начин. Друга ставка је да се примењена метода фокусира на минимално претпроцесирање тј да не подразумева детекцију сакада и фиксација, и да функционише само на основу сировог сигнала.

⁴ Ово поглавље представља резултате истраживања публикованог у [20].



Слика 15. Блок дијаграм алгоритма за примену конволуционе неуралне мреже за класификацију испитаника на основу координата тачке фокуса. Слика је преузета из [20] и прилагођена.


Бојење линија које спајају узастопне тачке олакшава разликовање брзих и спорих покрета очију, пошто је брзина узорковања фиксна. Дакле, боја сегмента одговара дужини линије тј. брзини кретања ока пошто су одбирци у времену еквидистантни. На овај начин кодирање боја сваке од секвенци података може послужити и као приближна замена за детекцију догађаја праћења ока, пошто ће дужи/бржи покрети бити приказани у другачијој боји у односу на кратке (Слика 17). Свака исцртана слика је коришћена као појединачна инстанца, у комбинацији са одговарајућом лабелом (дислексични образац или контролни образац) како би се формирао улазни скуп података који је коришћен за обучавање и евалуацију конволуционе неуралне мреже.



Слика 16. Дводимензионални прикази очних покрета испитаника са назначеним бржим и споријим очним покретима. Слика је преузета из [20] и прилагођена.

Архитектура неуралне мреже

Имплементирано је неколико конфигурација конволуционе неуралне мреже са циљем да се одреди која конфигурација на датом скупу даје најбоље резултате. Основна конфигурација је усвојена као модификација *VGG16* архитектуре [125], и коришћена је мрежа која није претренирана. Мрежа се састоји од улазног слоја, три блока (означени као А, Б и В на Слици 18), *flatten* слоја и једног неурона на излазном слоју (Слика 18).



Слика 17. Модификована архитектура *VGG16* неуралне мреже. Слика је преузета из [20] и прилагођена.

Улаз у мрежу је слика у боји добијена као обојена визуализација низа података, описаног у претходним пасусима. Улаз мреже има облик $64 \times 64 \times 3$ пиксела који представља димензије висина $\times$ ширина $\times$ канални боје слике. Ова величина слике је одабрана тако да се и сложени и једноставни обрасци погледа могу јасно уочити, без сувишно високе резолуције која би могла оптеретити процес обучавања неуралне мреже. Сваки од блокова садржи два конволуциона слоја, праћена слојем *batch normalization*, и једним *max pooling* слојем и *dropout* слојем (*dropout*

$rate = 0,5$). Број филтера варира од блока до блока, при чему блок А има 16 филтера, блок Б има 32 филтера и блок В има 64 филтера. Кораки за померање кернела свих конволуционих слојева су (1,1), коришћен је *NAdam* оптимизатор, бинарна крос ентропија као функција губитка и *batch size* од 128 за обучавање мреже. Све активационе функције у слојевима неуралне мреже су биле *ReLU* осим излазног неурона који је имао сигмоидну функцију активације.

Евалуација сваке од неуралних мрежа је урађена *subject-wise leave-one-out* унакрсном валидацијом тако да се цео скуп дели на 30 целина, једна целина (подаци једног испитаника) се користе за тестирање, а осталих 29 целина (подаци 29 испитаника) се користе за обучавање алгоритма. Процес се понавља 30 пута и подаци од сваког испитаника су тачно једном у скупу за тестирање. У оквиру процеса обучавања коришћено је рано заустављање, са тиме да је насумично 20% тренинг скупа узимано као валидациони скуп (на нивоу субјекта), а обучавање мреже се прекидало ако 20 епоха узастопно расте функција губитка на валидационом скупу (*patience* = 20). Максимални број епоха је 200, са тиме да је процес обучавање сваки пут заустављен раним заустављањем и никад није дошао до максималних 200 епоха. У свим испробаним архитектурама неуралне мреже су коришћени кернели квадратног облика, са тиме да су имплементирани мреже са три различите величине кернела за конволуционе слојеве (3×3 , 5×5 и 7×7) и две различите величине кернела за *max pooling* слојеве (2×2 и 4×4). Свака величина кернела конволуције је испробана са сваком величином кернела *max pooling* слоја, дајући укупно 6 комбинација.

Целокупна имплементација обраде података и дизајна неуралне мреже изведени су у програмском језику *Python* 3.8.1 [94]. Учитавање, обрада података и конверзија секевенци података у слике су урађени користећи *pandas* [95], *numpy* [96] и *matplotlib* [97] библиотеке. Имплементација неуралне мреже је изведена коришћењем библиотеке *tensorflow* (верзија 2.8.0) [126]. За све остале хиперпараметре модела и обучавања неуралних мрежа који нису експлицитно наведени, узете су подразумеване вредности дате у оквиру функција и метода наведених библиотека.

Свака од конфигурација неуралне мреже је евалуирана применом два приступа: 1) на нивоу инстанце података, и 2) на нивоу испитаника. Ниво инстанце података означава резултате класификације где је свака слика појединачно класификована, а као резултат се приказује просечна тачност свих инстанци података. Процена на нивоу испитаника подразумева да су све предикције за слике које припадају једном субјекту, за дату конфигурацију боја, усредњене, што резултира са укупно 13 предикција по испитанику (по једна предикција за сваку конфигурацију боја). Након тога, добија се просечно предвиђање за 13 конфигурација боја и упоређује се са правом лабелом испитаника. Први приступ представља природан начин евалуације на датом скупу података, док други приступ даје резултате који би били применљиви у пракси, тј. предлоге дијагноза за сваког испитаника. Истраживање утицаја конфигурације боја у овом случају није од интереса, са обзиром да неурална мрежа не даје никакву интерпретацију обележја, већ се посматра само могућност мреже да успостави тачну дијагнозу, а више конфигурација боја се само сматрају додатним подацима који могу допринети тачној предикцији.

Након стандардне евалуације, за сваку конфигурацију мреже засебно, а на свим спојеним тест скуповима урађен је и *Wilcoxon* тест рангова на основу предикција мреже. Овај тест је урађен како би се проверило да ли сепарабилност групе са дислексијом и контролне групе на основу предикција неуралне мреже има статистички значај.

8.2.2 Резултати и дискусија

Резултати унакресне валидације на нивоу инстанце су приказани у Табели 11, а на нивоу испитаника у Табели 12.

Табела 11. Резултати класификације на тест скупу, на нивоу инстанце, за све разматране конфигурације неуралне мреже.

Параметри модела		Тачност за поделу понављања на n сегмената		
кERNEL конволуције	<i>max pooling</i> кERNEL	$n = 3$	$n = 5$	$n = 10$
(3,3)	(2,2)	0.72	0.74	0.73
(3,3)	(4,4)	0.73	0.75	0.73
(5,5)	(2,2)	0.75	0.73	0.72
(5,5)	(4,4)	0.76	0.74	0.75
(7,7)	(2,2)	0.79	0.76	0.76
(7,7)	(4,4)	0.78	0.76	0.74

Табела 12. Резултати класификације на тест скупу, на нивоу испитаника, за све разматране конфигурације неуралне мреже.

Параметри модела		Тачност за поделу понављања на n сегмената		
кERNEL конволуције	<i>max pooling</i> кERNEL	$n = 3$	$n = 5$	$n = 10$
(3,3)	(2,2)	0.70	0.77	0.80
(3,3)	(4,4)	0.70	0.77	0.80
(5,5)	(2,2)	0.83	0.77	0.80
(5,5)	(4,4)	0.83	0.77	0.83
(7,7)	(2,2)	0.87	0.77	0.80
(7,7)	(4,4)	0.83	0.83	0.83

Може се приметити да је најбоља укупна постигнута тачност на нивоу инстанце података била 79% која је добијена за поделу понављања на 3 сегмента са величином конволуционог кERNELа од (7,7) и величином *max pooling* кERNELа од (2, 2). Иста конфигурација је дала најбоље резултате и на нивоу испитаника, постижући тачност од 87%. Укупна тачност зависи од конфигурације неуралне мреже као и од броја сегмената по понављању, али је доследно једнака или већа од 70% и за процену инстанце података и за процену испитаника.

Такође, спроведена је и статистичка анализа у виду *Wilcoxon* теста рангова на свим спојеним скуповима тестова, засебно за сваку дату конфигурацију, а између групе са дислексијом и контролне групе. Постигнута p вредност је била нижа од 0,001 за сваку конфигурацију мреже, што указује на јасну сепарабилност између класа датих предвиђањима неуралне мреже.

Најбољи добијени резултати постигнути су за најмањи број сегмената по понављању (3) са највећом посматраном величином конволуционог кернела и нижом величином *max pooling* кернела. Ово указује да неурална мрежа којој је дато више података на улазу на појединачној слици, са мањим укупним бројем инстанци инстанци (3 сегмента по понављању) може да добије боље резултате од оне са више инстанци, али мање података по појединачној слици (5 и 10 сегмената по понављању). Највећа величина конволуционог кернела указује на то да фокусна област сваког слоја треба да буде већа, и да фактор редукције података (који одговара величини *max pooling* кернела) треба да буде низак, омогућавајући да се максимална количина података пропагира кроз мрежу. Могло би се очекивати да ће модел са овом конфигурацијом показати знаке преобучавања, али у овом случају до тога није дошло. Преобучавање је избегнуто коришћењем раног заустављања у свакој целини унакрсне валидације.

Постигнута тачност (87%) у овом раду је мања од најбоље постигнутих од 96,9% добијених коришћењем конволуционих неуралних мрежа [16]. Ови резултати се могу сматрати очекиваним, јер је текст који је читан у оквиру експеримента написан на српском језику, а језик коришћен у експерименту у поменутој студији је шведски. Српски језик има много већу кореспонденцију између фонема и графема у поређењу са шведским, што отежава успостављање дијагнозе дислексије. Друга истраживања која користе обележја и алгоритме машинског учења дају сличне или боље резултате у односу на оне који су постигнути коришћењем неуралне мреже.

У методи описаној у секцији 7.3.1 обележја су издвојена за свако понављање појединачно, а а усредњена тачност класификације на нивоу субјекта је 96,7%. Овај проценат јесте значајно већи у односу на 87% добијених коришћењем неуралне мреже, али развој обележја и њихова примена захтевају дубљу анализу података и претпроцесирање, а и осетљива су на различите поставке експеримента и уређаје за праћење покрета очију. Дакле, у случају где постоји ограничен број података и где се ради са истом експерименталном поставком, резултати постигнути коришћењем обележја могу имати предности у односу на конволуционе неуралне мреже. У случају већег броја података са друге стране, комплексност неуралних мрежа и робусност њихових предикција може дати боље резултате. Иако је број студија које анализирају покрете очију у дислексији помоћу конволуционих неуралних мрежа сведен, добијене тачности, узимајући у обзир величину базе података, представљају добре индикаторе потенцијала за примену на већим узорцима. Ако се притом, узме у обзир успех дводимензионалних конволуционих неуралних мрежа у најразличитијим гранама обраде слике [127], њихов потенцијал у примени детекције дислексије постаје неспоран.

8.2.3 Закључак

У овој секцији представљен је метод за класификацију дислексије коришћењем дводимензионалних конволуционих неуралних мрежа. Испитано је неколико конфигурација пробне сегментације у комбинацији са неколико вредности за величину конволуционог кернела и *max pooling* кернела.

Најбоља постигнута тачност од 87% показује да дизајн експеримента који укључује податке о праћењу очију током читања на различитим конфигурацијама боја може произвести већу тачност од посматрања једне конфигурације. Најбоља постигнута тачност на нивоу инстанце је 79%, а

укупна тачност класификације испитаника већа је за 8% због усредњавања резултата за сваког субјекта на свим конфигурацијама боја.

Холистички приступ са минималном обрадом података представљен у овој секцији, у комбинацији са сликом у којој је брзина погледа кодирана бојом, показао се ефикасним када је упарен са савременим алгоритмима дубоког учења који постижу значајне резултате у класификацији слика. Подаци у форми слике су такође лакши за визуелизацију и тумачење, истовремено омогућавајући визуелну детекцију потенцијалних грешака у подацима, као што су грешке уређаја за праћење покрета ока, нерегистровани подаци о погледу или паузе током читања. Све ове појаве, притом видљиве на сликама, могу бити детектоване довољно софистицираним алгоритмима дубоког учења. Имајући у виду, да је принцип приказа погледа у формату слике омогућио развој нових обележја приказаних у секцији 7.3, може се сматрати да се на описаним сликама налази довољно информација које су потребне за веома успешну класификацију испитаника, и да је само питање доступности довољно велике базе података и одговарајуће архитектуре конволуционе неуралне мреже.

Правци за будући рад би укључивали аквизицију и анализирање веће базе података и анализу сигнала добијених са других сензорских система (откуцаја срца, електродермалне активности коже, ЕЕГ-а). Будући рад ће такође размотрити комбиновање скупа података коришћеног у овој секцији са другим скупом података који укључује мерења биометријских сигнала током читања, како због увећања доступних података за обучавање, тако и због тестирања робусности конволуционих неуралних мрежа приликом примене на различитим експерименталним поставкама.

8.3 Робусна детекција дислексије помоћу конволуционог аутоенкодера⁵


8.3.1 Метода

Истраживање представљено у овој секцији подразумева коришћење две базе података. Прва база је описана у шестом поглављу, у којој постоји 30 испитаника, 15 са дислексијом и 15 неуротипичних, чији је матерњи језик српски (База 1). Друга база података је прикупљена у [9] и садржи податке о покретима очију током читања од 185 испитаника чији је матерњи језик шведски (База 2).

База 2 садржи податке прикупљене од 88 контрола и 97 особа са дислексијом, узраста од 9 до 10 година; 145 мушких и 40 женских испитаника. Систем у форми наочара са инфрацрвеним камерама који прати рефлексију рожњаче, *Ober-2TM (Permobil Meditech*, Вобурн, Масачусетс, Сједињене Америчке Државе), коришћен је за праћење покрета очију (просторна резолуција од 5 минута), са фреквенцијом одабирања од 50 Hz. Сваки испитаник је снимљен једном, а током сваког снимања, испитаник је носио пар лаганих, индивидуално подесивих, наочара за праћење покрета очију на глави. Ослонац за браду и чело је постављен како би се минимизовали покрети главе и стабилизovala удаљеност гледања на 45 cm. Калибрација је извршена ручно пре сваког снимања подешавањем скалирања сигнала сваке осе посебно, за свако око. Сви испитаници су читали исти текст представљен на једној страници белог папира са црним словима, при чему се текст састојао од 10 реченица.

⁵ Ово поглавље представља резултате истраживања публикованог у [18].


Подаци о праћењу покрета очију сваког испитаника из оба скупа података су исечени да би се уклонили почетак и крај који не садрже покрете очију који представљају читање. Сви снимци из обе базе података су исечени на основу визуелне инспекције од стране два експерта и искључени су само делови испитивања који очигледно нису укључивали никакву активност читања. Укупно, ово је дало 378 исечених понављања (193 контролне групе, 185 особа са дислексијом) из Базе 1 и 181 (88 контрола, 93 испитаника са дислексијом) из Базе 2 (4 понављања су искључена јер ни почетак ни крај процеса читања нису били уочени у снимљеним подацима). Пример погледа приказаног у координатној равни $x - y$ (екран или папир) за обе групе испитаника (испитаници са дислексијом и неуротипични) и оба скупа података (База 1 и База 2) дат је на Слици 19 (два реда текста су издвојена ради јаснијег приказа).



Слика 18. Приказ обрасца погледа за две линије текста. База 1 лева колона, База 2 десна колона, испитаници са дислексијом горњи ред, контролни испитаници доњи ред. Слика је преузета из [18] и прилагођена.

Као што се може видети на Слици 19, чак и са обичним исцртавањем могу се уочити разлике у просторној комплексности погледа код испитаника са дислексијом и неуротипичних испитаника. За приказ је изабрано обично исцртавање, без увођења боја са обзиром да су димензије података другачије за обе базе, тако да униформна скала брзине не би била тривијална. Може се уочити и нешто већи степен детаља у покретима очију у Бази 1, што може бити последица веће фреквенције одабирања и врсте уређаја за праћење покрета очију.

Алгоритам обраде података у овом раду је осмишљен тако да се фокусира на просторну сложеност погледа и да не зависи од специфичности поставке експеримента и типа уређаја који се користи. Почетни корак у развијању алгоритма био је посматрање података из два доступна скупа података и анализа образаца читања. Као што је приказано у примерима датим на Слици 19, подаци из оба скупа показују да покрети очију имају хаотичнији образац код особа са дислексијом у поређењу са неуротипичним. Било је неопходно посматрати свако понављање не као целину, већ као низ мањих сегмената, како би се обезбедило да алгоритам обраде може да детектује исте хаотичне просторне тенденције у оба скупа података. Цео процес развоја и обучавања алгоритма за детекцију дислексије на једној бази података је дат на Слици 20.



Слика 19. Алгоритам обраде података за детекцију дислексије. Слика је преузета из [18] и прилагођена.


Корак број ① је екстракција x и y координата у функцији времена из сваког понављања. Овај корак подразумева уклањање трептаја/инстанци у којима подаци недостају и усредњавање

координата погледа са оба ока. Корак број ② представља поделу сваког понављања на већи број мањих сегмената и исцртавање координата које припадају сваком сегменту у $x - y$ равни. Овај корак осигурава да се сложеност погледа посматра локално у просторном домену. Ради одржавања конзистентне испуњености простора у коме се линије погледа исцртавају, сваки график је скалиран тако да испуни што већи део простора. Подаци су подељени на сегменте коришћењем временских прозора (ВП), а независно су примењене четири различите конфигурације. Посматране величине ВП су биле 0,5 s и 1 s, а узастопни ВП су померани за 0,2 s и 0,5 s. Све четири комбинације ових параметара су коришћене да би се испитало да ли би дужи или краћи ВП са већим или мањим преклапањем обезбедили најадекватнију поделу понављања на мање сегменте. Узимајући у обзир да се трајање читања разликује од понављања до понављања, постојаће различит број слика за свако понављање, што је узето у обзир у каснијим корацима обраде. Укупан број инстанци коришћених за обучавање аутоенкодера варира у зависности од конфигурације и базе, али у случају ВП величине 1 s и померања од 0,5 s, где је број инстанци најмањи, укупан број инстанци за Базу 1 је приближно 22000 а за Базу 2 износи 8800 инстанци.

Када су подаци подељени на временске сегменте и исцртани у $x - y$ координатној равни, они се претварају у слике исцртане у *grayscale* формату (у нијансама сиве). Линије су исцртане црном бојом, са провидношћу од 80% тако да се може уочити преклапање линија. Величина слика је скалирана у матрицу од 64×64 , са вредностима пиксела у распону од 0 до 255. Сlike су инвертоване, а вредности пиксела су нормализоване (подељене са 255) тако да је позадина црна, а линије светлије нијансе сиве, ради лакшег нумеричког израчунавања за конволуциони аутоенкодер.

Обучавање конволуционог аутоенкодера (корак ③) је спроведено на сликама описаним у преходном пасусу, користећи *batch size* 64, функцију губитка *binary cross-entropy* и *Adam* оптимизатор. *Binary cross-entropy* функција губитка је изабрана упркос томе што постоји континуирани опсег вредности пиксела да би се омогућио *label smoothing* и да би се омогућило истицање тачака у којима се линије секу [128]. Исте слике су дате на улаз и излаз конволуционог аутоенкодера, а мрежа је обучена да их реконструише. Скуп за тренинг је насумично подељен на стварни тренинг скуп (80%) и скуп за валидацију (20%). Максималан број епоха је постављен на 50.000 тако да се обука увек прекида раним заустављањем на основу функције губитка на скупу за валидацију (*patience* параметар 20). Активациона функција за све слојеве је била *ReLU*, осим за излазни слој који је имао сигмоидну активациону функцију. Архитектура конволуционог аутоенкодера је дата на Слици 21.

За обучавање конволуционог аутоенкодера су имплементирана два сценарија за одабир података, један где су само слике контролних испитаника коришћене за обучавање, а други где су сви доступни подаци из једног скупа података коришћени за обучавање. Метода која би била конвенционалнија за обучавање аутоенкодера је употреба само слика контролних испитаника. Међутим, узимајући у обзир природу података, чињеница да читаоци са дислексијом не показују потешкоће у читању у сваком тренутку, већ у одређеним интервалима, била је мотивација да се испробају оба сценарија и упореде резултати.




Слика 20. Архитектура конволуционог аутоенкодера. Слика је преузета из [18] и прилагођена.

Након обучавања аутоенкодера, свако понављање може бити представљено реконструкцијама слика које су биле креиране исцртавањем координата у $x - y$ равни (корак ④). Ове реконструкције су, уопштено посматрајући, сличније оригиналној слици за једноставније обрасце и мање сличне за сложеније или специфичније обрасце. За квантификацију сличности између изворних слика и реконструкција коришћена је метрика грешке израчуната као *binary cross-entropy* функција грешке између оригиналне слике и реконструкције. На овај начин свака слика реконструкције бива описана једном скаларном вредношћу – њеном одговарајућом грешком. Ниже вредности грешке указују на бољу реконструкцију која одговара једноставнијим (и чешћим) обрасцима погледа, а веће вредности грешке указују на реконструкцију која није била тако успешна, што одговара сложенијим (и мање честим) обрасцима погледа.

Након описивања сваке реконструкције слике вредношћу њене метрике грешке, низ метрика грешке једног покушаја је сортиран. Из низа метрика је издвојено пет обележја посматрањем разлика између 5 највећих и 5 најнижих вредности – корак ⑤ алгорита обраде. Илустрација овог поступка је дата на Сlici 22. Ово резултира тиме да је свако понављање представљено са 5 обележја, при чему обележја представљају распон између најбоље и најгоре реконструкције у оквиру тог понављања. Испитаници са дислексијом имају тенденцију да имају мање конзистентан образац погледа и понекад сложеније обрасце, тако да се очекује да 5 обележја које описују опсег сложености погледа имају веће вредности за субјекте са дислексијом у односу на неуротипичне испитанике.

Свако понављање, представљено са 5 обележја, лабелирано је према својој групи (група са дислексијом или контролна група), а скуп обележја и лабела се затим користи за и статистичку анализа коришћењем *Mann–Whitney* теста између група и заобучавање различитих алгоритама машинског учења. Разматрани алгоритми су *LR*, *KNN*, *SVM*, *RF* и *ada boost (AB)*. За сваки од алгоритама, извршен је *grid search* за најбољу конфигурацију хиперпараметара, користећи петоструку унакрсну валидацију на целом скупу података. За *LR* посматрани параметри су *penalty* (*l1*, *l2*, *elasticnet*), *C* (0,1, 0,5, 1, 2), *solver* (*newton-cg*, *lbfgs*, *liblinear*, *sag*, *saga*). За *KNN* посматрани су *n_neighbors* (2, 5, 10, 20), *weights* (*uniform*, *distance*), *algorithm* (*ball_tree*, *kd_tree*, *brute*). За *SVM* параметри од интереса су *C* (0,1, 0,5, 1, 2), *kernel* (*linear*, *poly*, *rbf*, *sigmoid*). За *RF* то су *n_estimators* (4, 6, 8, 10, 20, 40), *criterion* (*gini*, *entropy*, *log_loss*), *max_depth* (1, 2, 3, 4, 5, *None*), *max_features* (*sqrt*, *log2*). И на крају, за *AB* то су *n_estimators* (4, 6, 8, 10, 20, 40), *learning_rate* (0,1, 0,5, 1, 2). Након што је изабран најбољи хиперпараметар за сваки од алгоритама, они су обучени за цео скуп података. Овим се завршава корак ⑥ чији је резултат 5 обучених класификатора, који на основу издвојених обележја могу вршити предикције којој класи испитаник припада.

Цео процес обучавања алгоритама, који се састоји од 6 поменутих корака, имплементира се на једној бази и тестира на другој. Када се врши тестирање, стандардни кораци обраде (①, ② и ⑤) се изводе на исти начин као и током обучавања алгоритама. Аутоенкодер се користи за реконструкцију добијених улазних слика из базе која се користи за тестирање, али се обучава искључиво на подацима базе која је коришћена за обучавање. Исто важи и за алгоритме машинског учења који врше класификацију, обучени класификатори се користе на подацима за тестирање, али нису обучени на њима. На овај начин, цео алгоритам обраде се ефективно развија на једном скупу података и тестира на другом. И База 1 и База 2 су коришћене за обуку и тестирање, што показује да је алгоритам применљив и стабилан у оба смера: обучавање на Бази 1 и евалуација на Бази 2 и обучавање на Бази 2 и евалуација на Бази 1.




Слика 21. Екстракција обележја на основу грешака у реконструкцији слике, представљена за контролног испитаника и испитаника са дислексијом. Слика је преузета из [18] и прилагођена.

Метрике коришћене за процену перформанси класификатора су: Se , Sp , $F1\ score$, $AUROC$ и ACC . Сва обрада, имплементација алгорита и визуелизација података обављени су у *Python*

програмском језику, верзији 3.8.1 [94], користећи *pandas*[95], *numpy* [96], *matplotlib* [97], *sklearn* [103] и *tensorflow* (верзија 2.8.0) [126] библиотеке.

8.3.2 Резултати и дискусија

Резултати класификације су у великој мери засновани на квалитету обележја која су дата као улазни параметри, поготово код релативно малих база података. Да би се илустровала обележја изведена у развијеном алгоритму обраде, изабран је један сценарио евалуације (обучавање на Базе 2, евалуација на Базе 1, ВП величина 0,5 s, корак ВП 0,2 s, без података о испитаницима са дислексијом у скупу за обучавање аутоенкодера). Добијена обележја су приказана за обе базе података, за две класе, на Слици 23. помоћу *violin plot* приказа [129]. Може се видети јасна сепарабилност између класа, што указује да свако обележје појединачно ефикасно раздваја класе. Резултати статистичке анализе између групе са дислексијом и контролне групе дају исте резултате, тј. значајну разлику, $p < 0,001$ (за свако обележје и сценарио евалуације). Анализа је урађена на подацима из Базе 1 и Базе 2 одвојено. Ово, међутим, не чини обележја сувишним, јер више обележја пружа стабилније предвиђање за сваког појединца, пошто је процес издвајања обележја осетљив на *outlier*-е.



Слика 22. Издвојена обележја за један сценарио евалуације, приказана за контролну групу и групу са дислексијом из Базе 1 и Базе 2. Слика преузета из [18] и прилагођена.

Узимајући у обзир велики број комбинација алгоритама машинског учења, конфигурација ВП, сценарија обуке аутоенкодера и броја метрика, иницијално су представљени поједностављени резултати, дајући само тачност и *F1 score* алгоритма машинског учења са најбољим учинком за дати евалуациони сценарио. У Табели 13. приказани су резултати евалуације на Базе 2 (обучавање на Базе 1), а у Табели 14. резултати евалуације на Базе 1 (обучавање на Базе 2).

Резултати постигнути приликом евалуације на Бази 2 показују конзистентан *ACC* и *F1 score* постигнут у свим посматраним случајевима, а у већини њих се показало да је *LR* алгоритам са најбољим перформансама. Најбољи *ACC* и *F1 score* су 82,9% и 81,7%, респективно. Што се тиче резултата постигнутих приликом евалуације на Бази 1, чини се да на њих више утиче сценарио евалуације него што је то случај код евалуације на Бази 2. Најбоље остварен *ACC* је, међутим, нешто већи и износи 85,6%. *F1 score* за најбољи *ACC* је 84,9%, али најбољи *F1 score* је 85,2% и добија се за нешто нижи *ACC* од 85,3%.

Табела 13. Резултати евалуације на Бази 2 (обучавање на Бази 1).


Величина ВП [s]	Корак ВП [s]	Подаци испитаника са дислексијом за обучавање аутоенкодера	Алгоритам машинског учења	<i>ACC</i> [%]	<i>F1 score</i> [%]
0.5	0.5	Не	<i>LR</i>	81.8	82.0
0.5	0.5	Да	<i>LR</i>	80.7	80.2
0.5	0.2	Не	<i>LR</i>	81.2	80.5
0.5	0.2	Да	<i>AB</i>	81.8	81.8
1	0.5	Не	<i>LR</i>	81.8	80.9
1	0.5	Да	<i>AB</i>	81.2	80.0
1	0.2	Не	<i>LR</i>	82.3	81.2
1	0.2	Да	<i>LR</i>	82.9	81.7

Табела 14. Резултати евалуације на Бази 1 (обучавање на Бази 2).

Величина ВП [s]	Корак ВП [s]	Подаци испитаника са дислексијом за обучавање аутоенкодера	Алгоритам машинског учења	<i>ACC</i> [%]	<i>F1 score</i> [%]
0.5	0.5	Не	<i>LR</i>	78.9	78.5
0.5	0.5	Да	<i>RF</i>	84.1	83.4
0.5	0.2	Не	<i>LR</i>	85.6	84.9
0.5	0.2	Да	<i>AB</i>	85.3	85.2
1	0.5	Не	<i>LR</i>	82.5	85.2
1	0.5	Да	<i>LR</i>	82.5	82.0
1	0.2	Не	<i>LR</i>	81.0	79.6
1	0.2	Да	<i>SVM</i>	80.5	79.2

Све посматране метрике су приказане на Слици 24, за све алгоритме машинског учења, за најбоље резултате на Бази 2 и најбоље резултате на Бази 1.

Резултати приказани на Слици 24. показују различите аспекте евалуације на Бази 1 и Бази 2. Иако су резултати алгоритма машинског учења са најбољим учинком били прилично конзистентни за евалуацију на Бази 2 у смислу различитих сценарија у вези са конфигурацијом ВП и инклузивношћу субјеката са дислексијом у обучавање аутоенкодера, постоји прилично варијабилности у перформансама између различитих алгоритама машинског учења. Алгоритми са најбољим учинком су *LR* и *SVM*, који не показују разлику у *ACC* на другој децимали и имају најбоље резултате у другим метрикама, при чему *SVM* чак има већи *Se*.



Слика 23. Преглед метрика класификације за најбоље добијене резултате на Бази 1 и Бази 2 у смислу ВП и сценарија обучавања аутоенкодера, за све посматране алгоритме машинског учења. Слика преузета из [18] и прилагођена.

Остали алгоритми, иако и даље дају предвиђања боља од случајних, не дају тако добре перформансе. С друге стране, резултати између различитих алгоритама машинског учења су много конзистентнији у евалуацији на Бази 1. Варијације између резултата алгоритама су много мање него у евалуацији на Бази 2, упркос томе што је евалуација на Бази 1 осетљивија на конфигурацију ВП и инклузивност података о испитаницима са дислексијом у обучавању аутоенкодера. Ово показује да на различите скупове података могу утицати различити аспекти обраде и избора алгоритама машинског учења, који могу зависити од бројних фактора, као што су протокол експеримента, број учесника, осетљивост мерног инструмента, итд.

Тачност класификације која се налази у релевантној литератури варира у распону од 80% до 96,6% [9,11,130,12–15,17,20,72,77], при чему је највећа тачност од 94% на Бази 1 [17] и 96,6% на Бази 2 [16], што чини резултате класификације добијене у овом раду упоредивим са онима у литератури, али не и највишим. Имајући ово у виду, све поменуте студије које се фокусирају на откривање дислексије коришћењем праћења очију користе само један скуп података, при чему сви учесници имају исти матерњи језик, исти експериментални протокол, инструменте и структуру података. Метода представљена у овом поглављу, међутим, има за циљ да комбинује податке из више студија које се разликују у многим аспектима. Фокусирајући се на просторне карактеристике погледа, циљ развијене методе није био да се прикаже најбоља тачност у детекцији дислексије, већ да се представи алгоритама који би се универзално могао применити на податке из различитих

студија. Алгоритам који се може обучити на једном скупу података и користити на другом не постоји у литератури праћења покрета очију зарад успостављања дијагнозе дислексије. У представљеном истраживању, један скуп података [1] садржи читаче чији је матерњи језик српски, бесконтактни уређај за праћење покрета очију и екранску презентацију текста у различитим конфигурацијама боја, док други [9] садржи читаче чији је матерњи језик шведски, носиви уређај за праћење покрета очију и презентацију текста на белом папиру. Штавише, број субјеката (30 у Бази 1 наспрам 181 у Бази 2) и број понављања (378 у Бази 1 наспрам 181 у Бази 2) у два посматрана скупа података су такође различити. Количина текста приказаног у експериментима је такође различита, при чему База 1 има две или три реченице по покушају, док База 2 има 10 реченица. Посматрањем просторних карактеристика могли би се комбиновати експерименти са различитим количинама текста, пошто се у предложеном алгоритму не користи временски аспект података. Упркос разликама, алгоритам за обраду обучен на једном скупу података и тестиран на другом (и обрнуто) даје тачности упоредиве са онима у литератури. Такође, различити матерњи језици читалаца могу утицати на обележја праћења очију, пошто сви језици немају исту дубину ортографије. Ипак, показало се да су догађаји који показују да читаоци имају потешкоће са читањем појединих речи независни од тога да ли је у питању српски или шведски језик. Ово указује да дислексичне тенденције имају сличне манифестације на различитим језицима, барем у погледу просторних карактеристика погледа. Ово даје индикације да је уз адекватну комбинацију алгоритама машинског учења и класичне обраде могуће прећи језичку баријеру и омогућити откривање дислексије независно од језика и помоћу студија са различитим дизајном.

8.3.3 Закључак

У овој секцији је представљена нова метода за детекцију дислексије базирана на примени конволуционог аутоенкодера на сигнале очних покрета. Метода се фокусира на квантификацију просторне сложености сегмената погледа тако што их исцртава у равни приказа текста и представља их као слике у нијансама сиве. Слике су коришћене за обучавање конволуционог аутоенкодера, а сложеност погледа приказаног на свакој слици се квантификује као грешка реконструкције слике. Распони грешака реконструкције су извучени из сваког понављања читања и коришћени као улазна обележја за различите алгоритме машинског учења. Метода је евалуирана коришћењем два скупа података, обучавајући моделе на једном скупу података и евалуирајући их на другом. Најбоље постигнуте тачности су 85,6% када је евалуација урађена на Бази 1 и 82,9% када је евалуација урађена на Бази 2.

Развијена метода не зависи од поделе података погледа на фиксације и сакаде и не ослања се ни на какве временске аспекте везане за експеримент. Евалуација алгоритма је урађена на два скупа података са потпуно различитим експерименталним протоколима, групама испитаника и инструментима за праћење погледа. Добијени резултати, упоредиви са онима који се налазе у литератури, показују да је метод робустан и да превазилази различитости између студија. Будући рад би укључивао анализу и развијање алготима са више скупова података, имплементацију различитих типова конволуционих аутоенкодера и истраживање осетљивости метода на нижу просторну резолуцију коришћених уређаја за праћење покрета очију.

9 Закључак

9.1 Научни доприноси докторске дисертације

Дислексија представља неуробиолошки поремећај који погађа флуентност и тачност читања, као и разумевање прочитаног садржаја. Постоји велики број студија који се бави развојем различитих метода за детекцију и евалуацију дислексије, али не постоји у литератури развијена метода за детекцију дислексије на српском језику помоћу анализе покрета очију. У оквиру ове дисертације представљене су различите методе за детекцију дислексије код деце чији је матерњи језик српски. Развијене методе су засноване на мерењима очних покрета и приказана су два различита приступа за успостављање дијагнозе: приступ заснован на дизајну обележја и приступ заснован на минималном претпроцесирању и конволуционим неуралним мрежама.

Истраживање описано у оквиру ове дисертације је засновано на три хипотезе:

- Хипотеза 1. Обрасци покрета очију током читања на српском језику се разликују у просторном и временском домену између деце са дислексијом и неуротипичне деце тако да је могуће обезбедити аутоматску идентификацију дислексичних образаца;
- Хипотеза 2. У реалном времену, помоћу интерпретабилних и робусних обележја је могуће идентификовати дислексичне обрасце несегментираних очних покрета током читања на српском језику;
- Хипотеза 3. Могуће је развити алат за детекцију дислексичних тенденција на основу несегментираних сигнала очних покрета који се може применити у различитим експерименталним условима.

Научни доприноси остварени у оквиру спроведеног истраживања потврђују све постављене хипотезе, а одговарајућа образложења су наведена у наставку.

Хипотеза 1: Обрасци покрета очију током читања на српском језику се разликују у просторном и временском домену између деце са дислексијом и неуротипичне деце тако да је могуће обезбедити аутоматску идентификацију дислексичних образаца.

Одговор на ову хипотезу је дат резултатима постигнутим у секцији 7 ове дисертације, и то користећи више различитих приступа. Секција 7 описује детекцију дислексије користећи обележја изведена из очних покрета и примену алгоритама машинског учења. У секцији 7.3 су имплементирана конвенционална обележја изведена из очних покрета као и **нова предложена обележја која се заснивају на просторним и временским карактеристикама очних покрета**. Конвенционална и развијена обележја су коришћена појединачно за обучавање различитих алгоритама машинског учења, као и по групама (конвенционална, развијена, сва обележја). Постигнути резултати који износе 94% тачности за скуп развијених обележја и 91% тачности за једно од развијених обележја дају резултате боље од сваког појединачног конвенционалног обележја, и свих конвенционалних обележја заједно (најбољи резултат од 85% тачности). На овај начин је показано да се развијена обележја која су заснована на просторним карактеристикама погледа током читања могу користити не само у комбинацији са другим обележјима за класификацију, већ и индивидуално са високим степеном сепарабилности класа. Три уведена обележја која су се приликом рангирања значаја обележја издвојила као најзначајнија су коришћена и за даљу статистичку анализу. Анализа је урађена на свим конфигурацијама боја

заједно између група, као и на свакој конфигурацији боја појединачно и добијена је значајна статистичка разлика у свим случајевима ($p < 0.001$ у свим случајевима). Поређење између група је урађено на свакој конфигурацији засебно и тестирањем распршености вредности обележја и добијена је значајна разлика између група за све конфигурације ($p < 0.01$), дајући информацију да су подаци групе са дислексијом значајно распршенији на свакој конфигурацији у односу на контролну. На крају, урађена је и статистичка анализа у оквиру групе са дислексијом поређећи сваке две конфигурације боја како би се увидело да ли постоји конфигурација која даје ниже вредности обележја у односу на друге и тиме индикује да је на тој конфигурацији боја испитаницима са дислексијом лакше да читају текст. Резултати су дали само три пара конфигурација у којима је постојала статистички значајна разлика, дајући закључак да не постоји универзално најбоља конфигурација боја за читање текста. Додатна анализа утицаја боја је урађена у секцији 7.4, где су коришћена друга обележја, али је анализа резултовала истим закључком. Обележја су давала јасну сепарабилност између класа на свакој конфигурацији боја појединачно, и у овом случају урађен је још један вид поређења утицаја боја. Приказани су *boxplot* дијаграми обележја за случајеве када су класе максимално приближене и максимално раздвојене. Максимално приближавање група је постигнуто тиме што је сваки испитаник са дислексијом евалуиран на основу своје најбоље конфигурације боја, а сваки неуротипични на основу своје најгоре, док је за максимално раздвајање група урађен супротан процес. Поред *boxplot* дијаграма приказане су и расподеле конфигурација боја које представљају најбоље и најгоре конфигурације испитаника. Ова анализа је показала значај утицаја боја на сепарабилност класа, као и варијабилност конфигурација боја које могу бити најбоље/најгоре за одређену групу испитаника. **Сprovedена анализа утицаја боје на сепарабилност дислексичних и неуротипичних образаца очних покрета** у наведена два поглавља иде у прилог томе да је тешко изабрати универзално најбољу конфигурацију за читање, међутим да боје генерално имају значајан утицај, поготово на групу са дислексијом, и да индивидуалистички приступ има велики потенцијал у терапији и асистивним технологијама.

Хипотеза 2: У реалном времену, помоћу интерпретабилних и робусних обележја је могуће идентификовати дислексичне обрасце несегментираних очних покрета током читања на српском језику.

Потврда ове хипотезе је постигнута резултатима представљеним у секцији 7.4. Ова секција описује **развој робусних и интерпретабилних обележја очних покрета која омогућавају детекцију дислексичних тенденција у реалном времену током читања, а помоћу алгоритама машинског учења**. Развијена обележја се заснивају на просторној комплексности образаца читања, надовезујући се на резултате поглавља 7.3 уз неколико значајних искорака. Обележја развијена у поглављу 7.4 се заснивају само на сировим подацима очних покрета тј. на низу x и y координата очних покрета, без поделе на фиксације и сакаде. Естимација ових обележја се такође већински заснива на праћењу промене смера кретања погледа у вертикалном правцу, а на основу такозваних тригера. Тригери се детектују локалним самопресецима линије погледа или узастопном променом смера кретања по вертикалној оси, а након тригера се прати број промена смера вертикалног кретања у трајању од једне просечне фиксације (250 ms). Оваква имплементација обележја даје нешто мањи степен тачности у односу на она представљена у секцији 7.3 (88,9% тачности у односу на 91% за појединачно обележје) али зато се могу применити у реалном времену и имају много већи степен робусности. Подела очних покрета на фиксације и сакаде не представља тривијалан задатак, и различити алгоритми могу дати различите поделе, тако да независност обележја од ове поделе доприноси њиховој приступачности и робусности. Такође, развијена обележја су естимирана на сигнаlima са података прикупљених на изворних 60 Hz и са смањених 30 Hz. Тачност постигнута на 30 Hz износи 87,8% што иде у прилог томе да

су наведена обележја робусна и на нижој фреквенцији одабирања. Природа обележја која подразумева детекцију тригера, такође омогућава да се прате конкретни делови текста који су одговорни за повећање вредности обележја, а самим тим и дислексичних тенденција током читања.

Хипотеза 3: Могуће је развити алат за детекцију дислексичних тенденција на основу несегментираних сигнала очних покрета који се може применити у различитим експерименталним условима.

Потврда ове хипотезе је дата кроз резултате представљене у поглављу 8. Секција 8.2 представља иницијални корак који је подразумевао представљање снимака очних покрета у формату слике и примену конволуционе неуралне мреже за класификацију. Постигнута тачност на нивоу субјекта од 87% значи да је, уз конверзију очних покрета у формат слике, могуће применити **систем за детекцију дислексичних тенденција на основу несегментираних сигнала покрета очију током читања применом конволуционих неуралних мрежа**. Овај холистички приступ који захтева минимално претпроцесирање и не захтева поделу очних покрета на фиксације и сакаде је даље развијен у секцији 8.3. Примена свих алгоритама описаних у секцији 7 и у секцији 8.2 је урађена на бази података која обухвата 30 испитаника чији је матерњи језик српски. Секција 8.3 представља алгоритам обраде који је, поред базе коришћене у наведеним секцијама, примењен и на бази података прикупљеној у [9] која обухвата 181 испитаника чији је матерњи језик шведски. Ове две базе података прате очне покрете испитаника са дислексијом и неуротипичних испитаника током читања, али осим тога имају велики број разлика у погледу дизајна студије. Експериментална поставка, која укључује начин приказа текста, број реченица, број понављања по једном испитанику, уређај за праћење покрета очију и матерњи језик испитаника, се разликовала при прикупљању података две базе. Упркос овим разликама, коришћењем конволуционог аутоенкодера за квантификацију просторне комплексности очних покрета, као и алгоритама машинског учења, развијен је **нов систем за детекцију дислексичних тенденција на основу сигнала покрета очију током читања који показује висок степен робусности у погледу експерименталних услова**. Систем је обучен на једној бази а евалуиран на другој, и обрнуто, тако да је тестирана његова примена у реалном сценарију где се једна студија користи за његово обучавање, а затим се систем примењује у потпуно другачијој студији. Постигнута тачност приликом евалуације на бази очних покрета читача чији је матерњи језик српски износи 85,6%, а на бази очних покрета читача чији је матерњи језик шведски износи 82,9%. Ове тачности потпадају у опсег вредности које се појављују у литератури, и иако нису највеће, представљају прве успешне резултате примене интелигентног система обученог на једној бази података, а тестираног на другој бази података са потпуно другачијом експерименталном поставком. Постигнути резултати указују на потенцијал за наставак истраживања на конто резултата на анализираним базама података узимајући у обзир њихову величину.

9.2 Правци за даља истраживања

Правци за даља истраживања у овој области се могу поделити у две начелне групе:

1. Проширивање базе података спровођењем нових експеримената и укључивање података из других експеримената;
2. Увођење нових анализа и развијање нових алгоритама.

У првој категорији смерница за даљи рад могу се спроводити експерименти на српском језику, али са циљем да се истражи још стратегија за приказ текстуалног садржаја. Може се истраживати

утицај ширег спектра боја, различитих комбинација текста и боја, анализа различитих фонтова, прореда, поравнања текста као и укључивање додатних елемената поред текста, са циљем анализе утицаја визуелне гужве. Нови експерименти би такође подразумевали више понављања урађених за исту стратегију приказа како би се испратила конзистентност резултата. Спровођење нових студија такође обухвата и лонгитудиналне студије, где би се развијени алгоритми и обележја тестирали за потребе праћења терапије дислексије у сарадњи са експертима из дате области. Поред студија које су директно везане за српски језик, будући рад укључује и анализирање постојећих и нових база података које садрже податке испитаника са различитим матерњим језицима у циљу даље евалуације развијених метода и њихове робусности за различите експерименталне поставке.

Смернице за даљи рад друге категорије подразумевају даље развијање поменутих обележја која се заснивају на просторним карактеристикама. Развој нових обележја може имати за циљ побољшање постигнуте тачности, њихову робусност спрема квалитета уређаја за праћење покрета очију у просторном домену, као и њихову стабилност на унети шум. Развијање оваквих обележја представља значајан корак у смеру приступачног праћења дислексије. Обележја које не захтевају високу просторну и временску тачност, не оптерећују уређај комплексним рачунањем и имају висок степен отпорности на шум се могу користити у комбинацији са веб камерама за приступачно праћење и евалуацију дислексије. Развијање алгоритама за праћење покрета очију на основу снимака са веб камере такође представља једно од даљих усмерења истраживања. За потребе успостављања дијагнозе која примењује холистички приступ, у даља истраживања потпада имплементација различитих архитектура неуралних мрежа, као и тестирање различитих видова представљања (енг. *encoding*) података.

Као засебну категорију смерница за даљи рад које обухватају аспекте и прве и друге групе смерница издваја се дубље разумевања самог поремећаја дислексије. У складу са тим, даље смернице укључују анализирање других биомедицинских мерења попут ЕЕГ-а, електродермалне активности, откуцаја срца и фМР снимака, не само током читања, већ током различитих тестирања језичких способности. Свеобухватно разумевање дислексије такође подразумева диференцијалну дијагностику, тако да даљи рад може обухватати студије у којима се посматрају сличности и разлике симптома са другим типовима поремећаја попут поремећаја пажње, и развијање метода за успешно успостављање прецизне дијагнозе.

10 Прилог А – Пример слајдова коришћених у експерименту

Било неки богат сељак без среће, па пошао у свет да је потражи. На путу сретне једног старца седе браде до појаса, па га упита: „Знаш ли, старино, да ми кажеш где је моја срећа?“ „У раду“, одговори му старац.

Сељак се не задовољи овим одговором, већ пође даље. Опет сретне на путу другог старца седе браде до појаса, па га упита: „Знаш ли, старино, да ми кажеш где је моја срећа?“ – „У реду“, одговори му старац.

Сељак се не задовољи ни овим одговором, већ пође даље. Мало затим сретне на путу трећег старца седе браде до појаса, па и њега упита: где му је срећа. А он му одговори да је она у поштењу. Врдне сељак главом, па се намргди и пође даље.

Није био одмакао ни за један пушкет, а он опет сретне једног старца седе браде, па и њега упита за срећу, а он му одговори да је у добром здрављу. Не задовољи се сељак ни оваквим одговором, већ настави пут.

За мало, па опет сретне једног старца те и њега упита за срећу; а овај му рекне да је срећа у мирном, лепом и задовољном животу. Сељак је очекивао да му ови старци покажу место где се његова срећа налази, а они му одговарају нешто сасвим десето.

Зато науми да продужи пут даље. Путујући тако сретне опет једног старца седе косе и браде, па га упита за срећу, а он му одговори да се она налази у умерености и чистоти.

Слика А1. Пример слајдова коришћених у експерименту 1/2.

Овај није ни за то хтео да чује, већ пође даље. Најзад сретне једног калуђера с великом седом косом и брадом и светитељским лицем (а то је био свети Сава), те и њега упита:

„Часни оче, ја сам човек без среће, па ево где пођох у свет да је потражим, но те молим да ми кажеш: где је могу наћи?“
„Наћи ћеш је у себи самом“, одговори му свети Сава. „Ако си паметан, ти си и срећан, а ако си луд, ти си и без среће.

Ако си паметан, ти ћеш слушати савете, опомене и поуке паметних људи, који су много којешта претурили преко главе; а ако си без памети, нећеш никогa слушати и бићеш без среће“.

У калуђера је сељак имао велику наду да ће му бар рећи где му је срећа. Али кад му и он овако одговори, одлучи да даље не путује него да се врати кући, па да послуша савете овога калуђера и оних старца који му одговараху где му је срећа.


Кад је дошао кући, он је у њој увео рад, ред, и поштење, пазно на здравље, миран, леп и задовољан живот и умереност и чистоту. После овога све му се окренуло на боље. Кућа му је пропевала

Челад му је била весела, стока напредна, имање родно, он задовољан и срећан. Зато је више пута говорио:
„Е људи, ко би то мислио и ко би се томе надао да је срећа била у мени, у мојој памети и у мојим рукама.


А ја пошао по свету, као махнит, да је тражим, од немиле до недрага, и да је пађем. Хвала ономе духовнику, што ме поучи и врати. Да не беше њега, ја бих пропао тражећи срећу и никада је не бих нашао изван себе“.

Слика А2 Пример слајдова коришћених у експерименту 2/2.


11 Прилог Б – Визуелизација покрета очију током читања - база испитаника




Слика Б1. Приказ очних покрета контролног испитаника 1.




Слика Б2. Приказ очних покрета контролног испитаника 2.




Слика Б3. Приказ очних покрета контролног испитаника 3.




Слика Б4. Приказ очних покрета контролног испитаника 4.




Слика Б5. Приказ очних покрета контролног испитаника 5.




Слика Б6. Приказ очних покрета контролног испитаника 6.




Слика Б7. Приказ очних покрета контролног испитаника 7.




Слика Б8. Приказ очних покрета контролног испитаника 8.




Слика Б9. Приказ очних покрета контролног испитаника 9.




Слика Б10. Приказ очних покрета контролног испитаника 10.




Слика Б11. Приказ очних покрета контролног испитаника 11.




Слика Б12. Приказ очних покрета контролног испитаника 12.




Слика Б13. Приказ очних покрета контролног испитаника 13.




Слика Б14. Приказ очних покрета контролног испитаника 14.




Слика Б15. Приказ очних покрета контролног испитаника 15.




Слика Б16. Приказ очних покрета испитаника са дислексијом 1.




Слика Б17. Приказ очних покрета испитаника са дислексијом 2.




Слика Б18. Приказ очних покрета испитаника са дислексијом 3.




Слика Б19. Приказ очних покрета испитаника са дислексијом 4.




Слика Б20. Приказ очних покрета испитаника са дислексијом 5.




Слика Б21. Приказ очних покрета испитаника са дислексијом 6.




Слика Б22. Приказ очних покрета испитаника са дислексијом 7.




Слика Б23. Приказ очних покрета испитаника са дислексијом 8.




Слика Б24. Приказ очних покрета испитаника са дислексијом 9.




Слика Б25. Приказ очних покрета испитаника са дислексијом 10.




Слика Б26. Приказ очних покрета испитаника са дислексијом 11.




Слика Б27. Приказ очних покрета испитаника са дислексијом 12.



Слика Б28. Приказ очних покрета испитаника са дислексијом 13.



Слика Б29. Приказ очних покрета испитаника са дислексијом 14.



Слика Б30. Приказ очних покрета испитаника са дислексијом 15.

12 Прилог В – Алгоритми машинског учења

Алгоритми машинског учења представљају групу математичких модела који се могу користити за решавање проблема класификације, регресије и многих других, а за чију имплементацију је неопходно да постоји скуп података на коме алгоритми могу да „уче“. Алгоритми машинског учења се заснивају на оптимизацији функције губитка (енг. *loss function*) на основу које прилагођавају своје параметре и „уче“ одговарајуће обрасце. Оптимизација функције губитка се назива процес обучавања, и током овог процеса алгоритми на основу доступних података мењају вредности својих параметара. Постоји више различитих начина на које се алгоритми машинског учења могу обучавати, а најраспрострањенији се назива процес надгледаног учења и он подразумева да у бази податка постоји скуп улазних параметара и скуп излазних параметара. Током процеса обучавања, алгоритми машинског учења на основу доступних парова улазних и излазних података прилагођавају своје параметре и на тај начин мапирају улазне параметре на излазне. Начин на који алгоритми машинског учења мапирају улазне параметре на излазне се разликује од алгоритма до алгоритма. Такође, у оквиру исте групе алгоритама, могу се користити различити хиперпараметри, који представљају конфигурацију алгоритма и могу значајно да утичу на постигнуте резултате. У наставку је дат кратак преглед коришћених алгоритама, опис њиховог функционисања као и интерпретација њихових хиперпараметара.

Logistic regression (LR) је један од једноставнијих алгоритама машинског учења који се веома често користи у студијама. *LR* се заснива на оптимизацији функције губитка која посматра грешку између предикција и стварних вредности лабела. Овај алгоритам на основу базе података прави линеарни модел који дели простор обележја на дисјунктне регионе, а сваком региону се додељује припадност тачно једној класи. Овај алгоритам се обучава итеративно, помоћу оптимизатора функције губитка. У функцију губитка се често додаје још један члан који се односи на регуларизацију, који служи да ограничи вредност параметара модела. Ово може бити корисно са обзиром да *outlier*-и могу значајно утицати на вредности параметара модела и негативно утицати на целокупне перформансе, а то може бити регулисано фактором регуларизације. За овај алгоритам, хиперпараметри би били функција губитка (може бити квадратна – l_2 , апсолутна вредност – l_1 или комбинована), параметар регуларизације C , оптимизатор функције губитка, као и максималан број итерација за обучавање алгоритма.

K nearest neighbors (KNN) алгоритам нема параметре у класичном смислу, већ врши предикцију на основу посматрања k најближих вредности. Овај алгоритам када добије нови улазни скуп параметара за који је потребно да направи предикцију пронађе по метрици удаљености k најближих вредности из тренинг скупа, и провери која класа је у тих k података најзаступљенија. Она класа које је најзаступљенија се узима као предикција за унети скуп улазних параметара. Хиперпараметри овог модела би били број k најближих вредности које се посматрају, тип растојања (еуклидско, апсолутна вредност, итд) и алгоритам за одабир k најближих вредности (може се вршити претрага целог тренинг скупа, или алгоритам претраге заснован на стаблима одлучивања који оптимизују претрагу).

Support vector machine (SVM) алгоритам се заснива на максимизацији маргине између класа. Овај алгоритам, за разлику од *LR* у функцији губитка не оптимизује чисту разлику између предикције и лабеле, већ посматра растојање предикције од маргине одлучивања. Такође, постоји могућност додавања параметара регуларизације у функцију губитка који ограничава вредности параметра са истом мотивацијом као код *LR* алгоритма. Оно где се *SVM* значајно разликује од *LR* је коришћење такозваних кернела. *LR* алгоритам може раздвојити класе само ако су оне линеарно

сепарабилне, а исто важи и за линеаран *SVM*, међутим употреба кернела омогућава сепарабилност класа која није линеарна. Постоји више различитих типова кернела и они трансформишу улазни скуп параметара у други простор, правећи ефективно нови скуп улазних параметара. На овај начин оптимизација модела остаје линеарна, али је могуће постићи сепарабилност која није линеарна захваљујући прављењу новог скупа обележја. Хиперпараметри *SVM* алгоритма представљају параметар регуларизације C , тип кернела који се користи (линеарни, полиномијални, *Radial Basis Function*, итд.), оптимизатор функције губитка и максималан број итерација за обучавање.

Random forest (RF) алгоритам спада у групу такозваних *bagging* алгоритама, који се ослањају на више мањих структура које се појединачно обучавају а затим гласају како би се донела финална предикција. У оквиру *RF* алгоритма, мања структура која се обучава се зове стабло одлучивања (енг. *decision tree*). Једно стабло одлучивања се обучава тако што се на основу линеарних критеријума подаци итеративно деле на мање подскупове док се не дође до најмањих целина које, у идеалном случају, припадају само једној класи. Критеријуми и обележја на основу којих се врше ове поделе се одређују оптимизацијом ентропије или *Gini impurity* параметра. Одабир обележја и прага вредности обележја која ће разбити посматрани скуп на два дела бирају тако да вредности *Gini impurity* параметра или ентропије буду што мањи у новонасталим подељеним скуповима. У контексту машинског учења, *Gini impurity* и ентропија се могу сматрати функцијама губитка, са тиме да се оне итеративно рачунају за све новонастале поделе посматраног скупа на мање целине. Стабло одлучивања се, захваљујући природи процеса обучавања, обучава веома брзо, међутим не може самостално испратити комплексне обрасце у подацима. Овај недостатак се надомешћује *RF* алгоритмом, где постоји мноштво стабала одлучивања, где се свако стабло обучава на подскупу инстанци базе података и на подскупу обележја из базе података. На овај начин, свако стабло може да испрати другачије обрасце који се појављују у подацима и обележјима, а принцип гласања омогућава да финална предикција узима у обзир све наведене поделе које су стабла одлучивања направила. Хиперпараметри *RF* алгоритма су многобројни, али неки од најчешће разматраних су број стабла одлучивања, критеријум по коме се стабла одлучивања оптимизују (*Gini impurity* и ентропија), максимална дубина стабла одлучивања и функција за одређивање броја обележја за свако стабло спрам укупног броја обележја (корен, логаритам, итд.).

13 Прилог Г – Метрике за евалуацију класификатора базираног на обележјима

Табела Г1. *Sensitivity* параметар за појединачна обележја као улазе у алгоритме машинског учења.

	Обележје	Алгоритам машинског учења			
		<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Развијена обележја	Активно време читања	0.59	0.65	0.60	0.61
	Коефицијент самопресека фиксација	0.85	0.84	0.83	0.84
	Варијабилност интерсакадних интервала	0.54	0.61	0.62	0.58
	Варијабилност самопресека фиксација	0.85	0.82	0.85	0.85
	Средња фрактална димензија фиксација	0.84	0.87	0.83	0.84
Конвенционална обележја	Укупан број фиксација	0.74	0.78	0.76	0.77
	Укупно трајање фиксација	0.59	0.64	0.60	0.59
	Фреквенција фиксација	0.31	0.29	0.48	0.50
	Средње време трајања фиксација	0.32	0.33	0.43	0.50
	Укупан број сакада	0.74	0.75	0.82	0.83
	Укупно трајање сакада	0.59	0.64	0.61	0.59
	Фреквенција сакада	0.44	0.46	0.42	0.45
	Средње време трајања сакада	0.28	0.46	0.44	0.44
	Укупно време читања	0.61	0.65	0.59	0.62

Табела Г2. *Specificity* параметар за појединачна обележја као улазе у алгоритме машинског учења.

	Обележје	Алгоритам машинског учења			
		<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Развијена обележја	Активно време читања	0.95	0.83	0.89	0.90
	Коефицијент самопресека фиксација	0.95	0.96	0.93	0.94
	Варијабилност интерсакадних интервала	0.94	0.85	0.87	0.86
	Варијабилност самопресека фиксација	0.96	0.97	0.94	0.96
	Средња фрактална димензија фиксација	0.93	0.92	0.93	0.93

Конвенционална обележја	Укупан број фиксација	0.93	0.91	0.91	0.91
	Укупно трајање фиксација	0.95	0.83	0.92	0.91
	Фреквенција фиксација	0.39	0.34	0.59	0.76
	Средње време трајања фиксација	0.60	0.64	0.60	0.77
	Укупан број сакада	0.87	0.85	0.82	0.83
	Укупно трајање сакада	0.95	0.83	0.89	0.91
	Фреквенција сакада	0.70	0.47	0.73	0.70
	Средње време трајања сакада	0.69	0.66	0.81	0.70
	Укупно време читања	0.97	0.86	0.83	0.87

Табела Г3. *F1 score* параметар за појединачна обележја као улазе у алгоритме машинског учења.

	Обележје	Алгоритам машинског учења			
		<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Развијена обележја	Активно време читања	0.72	0.71	0.70	0.71
	Коефицијент самопресека фиксација	0.89	0.89	0.87	0.88
	Варијабилност интерсакадних интервала	0.67	0.69	0.70	0.68
	Варијабилност самопресека фиксација	0.90	0.89	0.89	0.90
	Средња фрактална димензија фиксација	0.88	0.89	0.87	0.88
Конвенционална обележја	Укупан број фиксација	0.81	0.83	0.82	0.83
	Укупно трајање фиксација	0.72	0.71	0.71	0.70
	Фреквенција фиксација	0.32	0.28	0.50	0.57
	Средње време трајања фиксација	0.37	0.39	0.47	0.58
	Укупан број сакада	0.78	0.79	0.82	0.83
	Укупно трајање сакада	0.72	0.71	0.71	0.70
	Фреквенција сакада	0.50	0.46	0.50	0.51
	Средње време трајања сакада	0.34	0.51	0.53	0.50
	Укупно време читања	0.74	0.73	0.67	0.71

Табела Г4. *AUROC* параметар за појединачна обележја као улазе у алгоритме машинског учења.

	Обележје	Алгоритам машинског учења			
		<i>LR</i>	<i>SVM</i>	<i>KNN</i>	<i>RF</i>
Развијена обележја	Активно време читања	s	0.79	0.73	0.75
	Коефицијент самопресека фиксација	0.94	0.95	0.92	0.94
	Варијабилност интерсакадних интервала	0.74	0.73	0.77	0.77
	Варијабилност самопресека фиксација	0.94	0.95	0.93	0.94
	Средња фрактална димензија фиксација	0.93	0.96	0.92	0.94
Конвенционална обележја	Укупан број фиксација	0.87	0.89	0.86	0.87
	Укупно трајање фиксација	0.67	0.78	0.72	0.72
	Фреквенција фиксација	0.37	0.32	0.59	0.61
	Средње време трајања фиксација	0.51	0.38	0.58	0.62
	Укупан број сакада	0.85	0.87	0.85	0.87
	Укупно трајање сакада	0.67	0.78	0.72	0.72
	Фреквенција сакада	0.53	0.34	0.59	0.58
	Средње време трајања сакада	0.40	0.54	0.60	0.58
	Укупно време читања	0.68	0.79	0.73	0.76

14 Референце

1. Jakovljević, T.; Janković, M.M.; Savić, A.M.; Soldatović, I.; Čolić, G.; Jakulin, T.J.; Papa, G.; Ković, V. The Relation between Physiological Parameters and Colour Modifications in Text Background and Overlay during Reading in Children with and without Dyslexia. *Brain Sci.* **2021**, *11*, doi:10.3390/brainsci11050539.
2. Roitsch, J.; Watson, S. An Overview of Dyslexia: Definition, Characteristics, Assessment, Identification, and Intervention. *Sci. J. Educ.* **2019**, *7*, 86, doi:10.11648/J.SJEDU.20190704.11.
3. Singer, E. Coping with academic failure, a study of Dutch children with dyslexia. *Dyslexia* **2008**, *14*, 314–333, doi:https://doi.org/10.1002/dys.352.
4. Lithari, E. Fractured academic identities: dyslexia, secondary education, self-esteem and school experiences. *Int. J. Incl. Educ.* **2019**, *23*, 280–296, doi:10.1080/13603116.2018.1433242.
5. Usman, O.L.; Muniyandi, R.C.; Omar, K.; Mohamad, M. Advance Machine Learning Methods for Dyslexia Biomarker Detection: A Review of Implementation Details and Challenges. *IEEE Access* **2021**, *9*, 36879–36897, doi:10.1109/ACCESS.2021.3062709.
6. Alexander, A.W.; Slinger-Constant, A.-M. Current Status of Treatments for Dyslexia: Critical Review. *J. Child Neurol.* **2004**, *19*, 744–758, doi:10.1177/08830738040190100401.
7. Arns, M.; Peters, S.; Breteler, R.; Verhoeven, L. Different brain activation patterns in dyslexic children: evidence from EEG power and coherence patterns for the double-deficit theory of dyslexia. *J. Integr. Neurosci.* **2007**, *06*, 175–190, doi:10.1142/S0219635207001404.
8. García Chimeno, Y.; García Zapirain, B.; Saralegui Prieto, I.; Fernandez-Ruanova, B. Automatic classification of dyslexic children by applying machine learning to fMRI images. *Biomed. Mater. Eng.* **2014**, *24*, 2995–3002, doi:10.3233/BME-141120.
9. Nilsson Benfatto, M.; Öqvist Seimyr, G.; Ygge, J.; Pansell, T.; Rydberg, A.; Jacobson, C. Screening for Dyslexia Using Eye Tracking during Reading. *PLoS One* **2016**, *11*, e0165508, doi:https://doi.org/10.1371/journal.pone.0165508.
10. Pavlidis, G.T. Eye Movements in Dyslexia: Their Diagnostic Significance. *J. Learn. Disabil.* **1985**, *18*, 42–50, doi:10.1177/002221948501800109.
11. Appadurai, J.P.; Bhargavi, R. Eye Movement Feature Set and Predictive Model for Dyslexia: Feature Set and Predictive Model for Dyslexia. *Int. J. Cogn. Informatics Nat. Intell.* **2021**, *15*, 1–22, doi:10.4018/IJCINI.20211001.0a28.
12. Raatikainen, P.; Hautala, J.; Loberg, O.; Kärkkäinen, T.; Leppänen, P.; Nieminen, P. Detection of developmental dyslexia with machine learning using eye movement data. *Array* **2021**, *12*, 100087, doi:https://doi.org/10.1016/j.array.2021.100087.
13. Asvestopoulou, T.; Manousaki, V.; Psistakis, A.; Smyrnakis, I.; Andreadakis, V.; Aslanides, I.M.; Papadopoulou, M. Dyslexml: Screening tool for dyslexia using machine learning. *arXiv Prepr. arXiv1903.06274* **2019**.
14. El Hmimdi, A.E.; Ward, L.M.; Palpanas, T.; Kapoula, Z. Predicting Dyslexia and Reading Speed in Adolescents from Eye Movements in Reading and Non-Reading Tasks: A Machine Learning Approach. *Brain Sci.* **2021**, *11*, doi:10.3390/brainsci11101337.

15. Rello, L.; Ballesteros, M. Detecting Readers with Dyslexia Using Machine Learning with Eye Tracking Measures. In Proceedings of the Proceedings of the 12th International Web for All Conference; Association for Computing Machinery: New York, NY, USA, 2015.
16. Nerušil, B.; Polec, J.; Škunda, J.; Kačur, J. Eye tracking based dyslexia detection using a holistic approach. *Sci. Rep.* **2021**, *11*, 15687, doi:10.1038/s41598-021-95275-1.
17. Vajs, I.; Ković, V.; Papić, T.; Savić, A.M.; Janković, M.M. Spatiotemporal Eye-Tracking Feature Set for Improved Recognition of Dyslexic Reading Patterns in Children. *Sensors* **2022**, *22*, doi:10.3390/s22134900.
18. Vajs, I.A.; Kvaščev, G.S.; Papić, T.M.; Janković, M.M. Eye-Tracking Image Encoding: Autoencoders for the Crossing of Language Boundaries in Developmental Dyslexia Detection. *IEEE Access* **2023**, *11*, 3024–3033, doi:10.1109/ACCESS.2023.3234438.
19. Vajs, I.; Papić, T.; Ković, V.; Savić, A.M.; Janković, M.M. Accessible Dyslexia Detection with Real-Time Reading Feedback through Robust Interpretable Eye-Tracking Features. *Brain Sci.* **2023**, *13*, doi:10.3390/brainsci13030405.
20. Vajs, I.; Ković, V.; Papić, T.; Savić, A.M.; Janković, M.M. Dyslexia detection in children using eye tracking data based on VGG16 network. In Proceedings of the 30th European Signal Processing Conference (EUSIPCO); Belgrade, 2022.
21. Roitsch, J.; Watson, S.M. An overview of dyslexia: definition, characteristics, assessment, identification, and intervention. *Sci. J. Educ.* **2019**, *7*, 86, doi:10.11648/J.SJEDU.20190704.11.
22. Definition of Dyslexia - The International Dyslexia Association Available online: <https://dyslexiaida.org/definition-of-dyslexia/> (accessed on Sep 21, 2023).
23. What is dyslexia - European Dyslexia Association Available online: <https://eda-info.eu/what-is-dyslexia/> (accessed on Sep 15, 2023).
24. What Is Specific Learning Disorder? - American Psychiatric Association Available online: <https://www.psychiatry.org/patients-families/specific-learning-disorder/what-is-specific-learning-disorder> (accessed on Sep 20, 2023).
25. Wagner, R.K.; Zirps, F.A.; Edwards, A.A.; Wood, S.G.; Joyner, R.E.; Becker, B.J.; Liu, G.; Beal, B. The Prevalence of Dyslexia: A New Approach to Its Estimation. *J. Learn. Disabil.* **2020**, *53*, 354–365, doi:10.1177/0022219420920377.
26. Sadusky, A.; Berger, E.P.; Reupert, A.E.; Freeman, N.C. Methods used by psychologists for identifying dyslexia: A systematic review. *Dyslexia* **2022**, *28*, 132–148, doi:https://doi.org/10.1002/dys.1706.
27. Stagg, S.D.; Eaton, E.; Sjoblom, A.M. Self-efficacy in undergraduate students with dyslexia: a mixed methods investigation. *Br. J. Spec. Educ.* **2018**, *45*, 26–42, doi:https://doi.org/10.1111/1467-8578.12200.
28. Wilmot, A.; Pizzey, H.; Leitão, S.; Hasking, P.; Boyes, M. Growing up with dyslexia: Child and parent perspectives on school struggles, self-esteem, and mental health. *Dyslexia* **2023**, *29*, 40–54, doi:https://doi.org/10.1002/dys.1729.
29. Blachman, B.A. *Phonological awareness.*; Lawrence Erlbaum Associates Publishers: Mahwah, NJ, US, 2000; ISBN 0-8058-2398-0 (Hardcover); 0-8058-2399-9 (Paperback).

30. Mitchell, J.-J. Comprehensive Test of Phonological Processing. *Assess. Eff. Interv.* **2001**, *26*, 57–63, doi:10.1177/073724770102600305.
31. Brooks, B.L.; Sherman, E.M.S.; Strauss, E. NEPSY-II: A Developmental Neuropsychological Assessment, Second Edition. *Child Neuropsychol.* **2009**, *16*, 80–101, doi:10.1080/09297040903146966.
32. Wiig, E.; Secord, W. ELLA – Emerging Literacy & Language Assessment Available online: <https://www.superduperinc.com/ella-emerging-literacy-language-assessment.html> (accessed on Sep 21, 2023).
33. Torgesen, J.; Wagner, R.K.; Rashotte, C.A. Test of Word Reading Efficiency 2 (TOWRE 2) Available online: <https://www.pearsonclinical.com.au/store/auassessments/en/Store/Professional-Assessments/Speech-%26-Language/Literacy/Test-of-Word-Reading-Efficiency-2/p/P100010178.html#:~:text=The Test of Word Reading,Decoding Efficiency>) accurately and fluently. (accessed on Sep 20, 2023).
34. Wechsler, D. Wechsler Individual Achievement Test - Third UK Edition (WIAT-III UK) Available online: <https://www.pearsonclinical.co.uk/store/ukassessments/en/Store/Professional-Assessments/Academic-Learning/Reading/Wechsler-Individual-Achievement-Test---Third-UK-Edition/p/P100009274.html> (accessed on Sep 15, 2023).
35. Wiederholt, J.L.; Bryant, B.R. Gray Oral Reading Test - Fifth Edition (GORT-5) Available online: <https://www.pearsonassessments.com/store/usassessments/en/Store/Professional-Assessments/Speech-%26-Language/Gray-Oral-Reading-Test-%7C-Fifth-Edition/p/100000106.html> (accessed on Sep 20, 2023).
36. Wolf, M.; Bridge Denckla, M. Rapid Automatized Naming and Rapid Alternating Stimulus Tests (RAN/RAS) Available online: <https://www.wpspublish.com/ran-ras-rapid-automatized-naming-and-rapid-alternating-stimulus-tests> (accessed on Sep 20, 2023).
37. Milankov, V. Deficit fonološke svesnosti kod dece sa disleksijom i disortografijom, PhD thesis, Univerzitet u Novom Sadu, 2016.
38. Čolić, G. Rani pokazatelji disleksije i disgrafije, PhD thesis, Univerzitet u Beogradu, 2016.
39. Caravolas, M. *The Nature and Causes of Dyslexia in Different Languages*.; Blackwell handbooks of developmental psychology.; Blackwell Publishing: Malden, 2005; ISBN 1-4051-1488-6 (Hardcover); 978-1-4051-1488-2 (Hardcover).
40. Levin Bowman, Fran Culotta, V. Dyslexia Self-Assessment Tool Available online: <https://dyslexiaida.org/dyslexia-test/> (accessed on Sep 20, 2023).
41. Dynaread Online Dyslexia Test Available online: <https://www.dynaread.com/online-dyslexia-test> (accessed on Sep 20, 2023).
42. Lexercise Dyslexia screening Available online: <https://www.lexercise.com/tests/dyslexia-test> (accessed on Sep 19, 2023).
43. DeYoe, E.A.; Bandettini, P.; Neitz, J.; Miller, D.; Winans, P. Functional magnetic resonance imaging (fMRI) of the human brain. *J. Neurosci. Methods* **1994**, *54*, 171–187, doi:[https://doi.org/10.1016/0165-0270\(94\)90191-0](https://doi.org/10.1016/0165-0270(94)90191-0).

44. Peyrin, C.; Lallier, M.; Démonet, J.F.; Pernet, C.; Baciú, M.; Le Bas, J.F.; Valdois, S. Neural dissociation of phonological and visual attention span disorders in developmental dyslexia: fMRI evidence from two case reports. *Brain Lang.* **2012**, *120*, 381–394, doi:<https://doi.org/10.1016/j.bandl.2011.12.015>.
45. Lobier, M.A.; Peyrin, C.; Pichat, C.; Le Bas, J.-F.; Valdois, S. Visual processing of multiple elements in the dyslexic brain: evidence for a superior parietal dysfunction. *Front. Hum. Neurosci.* **2014**, *8*, doi:<https://doi.org/10.3389/fnhum.2014.00479>.
46. Beneventi, H.; Tønnessen, F.E.; Ersland, L.; Hugdahl, K. Working Memory Deficit in Dyslexia: Behavioral and fMRI Evidence. *Int. J. Neurosci.* **2010**, *120*, 51–59, doi:[10.3109/00207450903275129](https://doi.org/10.3109/00207450903275129).
47. Gosse, C.; Dricot, L.; Van Reybroeck, M. Evidence of graphomotor dysfunction in children with dyslexia: A combined behavioural and fMRI experiment. *Cortex* **2022**, *148*, 68–88, doi:<https://doi.org/10.1016/j.cortex.2021.11.021>.
48. Yang, Y.; Yang, Y.H.; Li, J.; Xu, M.; Bi, H.-Y. An audiovisual integration deficit underlies reading failure in nontransparent writing systems: An fMRI study of Chinese children with dyslexia. *J. Neurolinguistics* **2020**, *54*, 100884, doi:<https://doi.org/10.1016/j.jneuroling.2019.100884>.
49. Jednoróg, K.; Gawron, N.; Marchewka, A.; Heim, S.; Grabowska, A. Cognitive subtypes of dyslexia are characterized by distinct patterns of grey matter volume. *Brain Struct. Funct.* **2014**, *219*, 1697–1707, doi:[10.1007/s00429-013-0595-6](https://doi.org/10.1007/s00429-013-0595-6).
50. Williams, E.L.; El-Baz, A.; Nitzken, M.; Switala, A.E.; Casanova, M.F. Spherical harmonic analysis of cortical complexity in autism and dyslexia. *Transl. Neurosci.* **2012**, *3*, 36–40, doi:[10.2478/s13380-012-0008-y](https://doi.org/10.2478/s13380-012-0008-y).
51. Tamboer, P.; Vorst, H.C.M.; Ghebreab, S.; Scholte, H.S. Machine learning and dyslexia: Classification of individual structural neuro-imaging scans of students with and without dyslexia. *NeuroImage Clin.* **2016**, *11*, 508–514, doi:<https://doi.org/10.1016/j.nicl.2016.03.014>.
52. Evans, T.M.; Flowers, D.L.; Napoliello, E.M.; Eden, G.F. Sex-specific gray matter volume differences in females with developmental dyslexia. *Brain Struct. Funct.* **2014**, *219*, 1041–1054, doi:[10.1007/s00429-013-0552-4](https://doi.org/10.1007/s00429-013-0552-4).
53. Strother, S.C. Evaluating fMRI preprocessing pipelines. *IEEE Eng. Med. Biol. Mag.* **2006**, *25*, 27–41, doi:[10.1109/MEMB.2006.1607667](https://doi.org/10.1109/MEMB.2006.1607667).
54. Binnie, C.D.; Prior, P.F. Electroencephalography. *J. Neurol. Neurosurg. Psychiatry* **1994**, *57*, 1308–1319, doi:[10.1136/jnnp.57.11.1308](https://doi.org/10.1136/jnnp.57.11.1308).
55. Homan, R.W. The 10-20 Electrode System and Cerebral Location. *Am. J. EEG Technol.* **1988**, *28*, 269–279, doi:[10.1080/00029238.1988.11080272](https://doi.org/10.1080/00029238.1988.11080272).
56. Larson, E.; Gramfort, A.; Engemann, D.A.; Leppakangas, J.; Brodbeck, C.; Jas, M.; Brooks, T.; Sassenhagen, J.; Luessi, M.; McCloy, D.; et al. MNE-Python. **2023**, doi:[10.5281/zenodo.8322569](https://doi.org/10.5281/zenodo.8322569).
57. Fraga González, G.; Van der Molen, M.J.W.; Žarić, G.; Bonte, M.; Tijms, J.; Blomert, L.; Stam, C.J.; Van der Molen, M.W. Graph analysis of EEG resting state functional networks in dyslexic readers. *Clin. Neurophysiol. Off. J. Int. Fed. Clin. Neurophysiol.* **2016**, *127*, 3165–3175, doi:[10.1016/j.clinph.2016.06.023](https://doi.org/10.1016/j.clinph.2016.06.023).

58. Xue, H.; Wang, Z.; Tan, Y.; Yang, H.; Fu, W.; Xue, L.; Zhao, J. Resting-state EEG reveals global network deficiency in dyslexic children. *Neuropsychologia* **2020**, *138*, 107343, doi:<https://doi.org/10.1016/j.neuropsychologia.2020.107343>.
59. Spironelli, C.; Penolazzi, B.; Angrilli, A. Dysfunctional hemispheric asymmetry of theta and beta EEG activity during linguistic tasks in developmental dyslexia. *Biol. Psychol.* **2008**, *77*, 123–131, doi:<https://doi.org/10.1016/j.biopsycho.2007.09.009>.
60. Žarić, G.; Correia, J.M.; Fraga González, G.; Tijms, J.; van der Molen, M.W.; Blomert, L.; Bonte, M. Altered patterns of directed connectivity within the reading network of dyslexic children and their relation to reading dysfluency. *Dev. Cogn. Neurosci.* **2017**, *23*, 1–13, doi:<https://doi.org/10.1016/j.dcn.2016.11.003>.
61. Taskov, T.; Dushanova, J. Reading-Network in Developmental Dyslexia before and after Visual Training. *Symmetry (Basel)*. **2020**, *12*.
62. Stam, C.J.; Nolte, G.; Daffertshofer, A. Phase lag index: assessment of functional connectivity from multi channel EEG and MEG with diminished bias from common sources. *Hum. Brain Mapp.* **2007**, *28*, 1178–1193, doi:[10.1002/hbm.20346](https://doi.org/10.1002/hbm.20346).
63. Kruskal, J.B. On the shortest spanning subtree of a graph and the traveling salesman problem. *Proc. Am. Math. Soc.* **1956**, *7*, 48–50, doi:<https://doi.org/10.2307/2033241>.
64. Blinowska, K.J. Review of the methods of determination of directed connectivity from multichannel data. *Med. Biol. Eng. Comput.* **2011**, *49*, 521–529, doi:[10.1007/s11517-011-0739-x](https://doi.org/10.1007/s11517-011-0739-x).
65. Taskov, T.; Dushanova, J. Reading-Network in Developmental Dyslexia before and after Visual Training. *Symmetry (Basel)*. **2020**, *12*, doi:[10.3390/sym12111842](https://doi.org/10.3390/sym12111842).
66. Klein, C.; Ettinger, U. *Eye movement research: An introduction to its scientific foundations and applications*; Springer Nature, 2019; ISBN 303020085X.
67. Lim, J.Z.; Mountstephens, J.; Teo, J. Emotion Recognition Using Eye-Tracking: Taxonomy, Review and Current Challenges. *Sensors* **2020**, *20*, doi:[10.3390/s20082384](https://doi.org/10.3390/s20082384).
68. Pavlidis, G.T. Do eye movements hold the key to dyslexia? *Neuropsychologia* **1981**, *19*, 57–64, doi:[https://doi.org/10.1016/0028-3932\(81\)90044-0](https://doi.org/10.1016/0028-3932(81)90044-0).
69. Prado, C.; Dubois, M.; Valdois, S. The eye movements of dyslexic children during reading and visual search: Impact of the visual attention span. *Vision Res.* **2007**, *47*, 2521–2530, doi:<https://doi.org/10.1016/j.visres.2007.06.001>.
70. Weiss, B.; Szalma, J.; Vidnyánszky, Z. Data-driven detection of developmental dyslexia: A machine learning approach based on behavioral and eye-movement features. **2022**, doi:[10.31234/osf.io/qasnc](https://doi.org/10.31234/osf.io/qasnc).
71. Stuart, S.; Hickey, A.; Vitorio, R.; Welman, K.; Foo, S.; Keen, D.; Godfrey, A. Eye-tracker algorithms to detect saccades during static and dynamic tasks: a structured review. *Physiol. Meas.* **2019**, *40*, 02TR01, doi:[10.1088/1361-6579/ab02ab](https://doi.org/10.1088/1361-6579/ab02ab).
72. Jothi Prabha, A.; Bhargavi, R. Predictive Model for Dyslexia from Fixations and Saccadic Eye Movement Events. *Comput. Methods Programs Biomed.* **2020**, *195*, 105538, doi:[10.1016/j.cmpb.2020.105538](https://doi.org/10.1016/j.cmpb.2020.105538).
73. Dixon, W.J.; Massey Jr., F.J. *Introduction to statistical analysis.*; McGraw-Hill: New York, NY,

US, 1951;

74. Ferguson, G.A. *Statistical analysis in psychology and education.*; McGraw-Hill: New York, NY, US, 1959;
75. Jakovljević, T.; Janković, M.M.; Savić, A.M.; Soldatović, I.; Todorović, P.; Jere Jakulin, T.; Papa, G.; Ković, V. The Sensor Hub for Detecting the Developmental Characteristics in Reading in Children on a White vs. Colored Background/Colored Overlays. *Sensors* **2021**, *21*, doi:10.3390/s21020406.
76. Prabha, J.A.; Bhargavi, R.; Harish, B. Predictive Model for Dyslexia from Eye Fixation Events. *Int. J. Eng. Adv. Technol.* **2019**, *9*, doi:10.35940/ijeat.A1045.1291S319.
77. Prabha, A.J.; Bhargavi, R.; Harish, B. An Efficient Machine Learning Model for Prediction of Dyslexia from Eye Fixation Events. *New Approaches Eng. Res. Vol. 10* **2021**, 171–179, doi:10.9734/bpi/naer/v10/11914D.
78. Snowling, M.J. Early identification and interventions for dyslexia: a contemporary view. *J. Res. Spec. Educ. Needs* **2013**, *13*, 7–14, doi:https://doi.org/10.1111/j.1471-3802.2012.01262.x.
79. Ritchey, K.D.; Goeke, J.L. Orton-Gillingham and Orton-Gillingham—Based Reading Instruction: A Review of the Literature. *J. Spec. Educ.* **2006**, *40*, 171–183, doi:10.1177/00224669060400030501.
80. Jaramillo-Alcázar, A.; Venegas, E.; Criollo-C, S.; Luján-Mora, S. An Approach to Accessible Serious Games for People with Dyslexia. *Sustainability* **2021**, *13*, doi:10.3390/su13052507.
81. Tammase, T.; Tammase, J.; Utami, I.F.; Rahman, F.F. The Effectiveness of Using Kinect-Based Dyslexia Therapy in Improving Reading Ability in Dyslexic Children: A Linguistic Study. *ELS J. Interdiscip. Stud. Humanit.* **2022**, *5*, 515–523, doi:10.34050/elsjish.v5i3.23168.
82. Habib, M.; Lardy, C.; Desiles, T.; Commeiras, C.; Chobert, J.; Besson, M. Music and Dyslexia: A New Musical Training Method to Improve Reading and Related Disorders. *Front. Psychol.* **2016**, *7*, doi:https://doi.org/10.3389/fpsyg.2016.00026.
83. Smith, C.; Hattingh, M.J. Assistive Technologies for Students with Dyslexia: A Systematic Literature Review BT - Innovative Technologies and Learning.; Huang, T.-C., Wu, T.-T., Barroso, J., Sandnes, F.E., Martins, P., Huang, Y.-M., Eds.; Springer International Publishing: Cham, 2020; pp. 504–513.
84. Dawson, K.; Antonenko, P.; Lane, H.; Zhu, J. Assistive Technologies to Support Students With Dyslexia. *Teach. Except. Child.* **2018**, *51*, 226–239, doi:10.1177/0040059918794027.
85. Rello, L.; Baeza-Yates, R. How to present more readable text for people with dyslexia. *Univers. Access Inf. Soc.* **2017**, *16*, 29–49, doi:10.1007/s10209-015-0438-8.
86. Jakovljević, T.; Janković, M.M.; Savić, A.M.; Soldatović, I.; Todorović, P.; Jere Jakulin, T.; Papa, G.; Ković, V. The Sensor Hub for Detecting the Developmental Characteristics in Reading in Children on a White vs. Colored Background/Colored Overlays. *Sensors* **2021**, *21*, doi:10.3390/s21020406.
87. Creating a dyslexia friendly workplace Available online: <https://www.bdadyslexia.org.uk/advice/employers/creating-a-dyslexia-friendly-workplace/dyslexia-friendly-style-guide#:~:text=Font size should be 12,excessive it can reduce>

readability. (accessed on Sep 22, 2023).

88. Rello, L.; Baeza-Yates, R. Good Fonts for Dyslexia. In Proceedings of the Proceedings of the 15th International ACM SIGACCESS Conference on Computers and Accessibility; Association for Computing Machinery: New York, NY, USA, 2013.
89. Dyslexia Font and Style Guide Available online: <https://www.dyslexia-reading-well.com/dyslexia-font.html> (accessed on Sep 20, 2023).
90. Open dyslexic font Available online: <https://opendyslexic.org/> (accessed on Sep 20, 2023).
91. Janković, M.M. Biomarker-based approaches for dyslexia screening: A review. In Proceedings of the 2022 ZINC; IEEE, 2022.
92. Clifton, C.; Staub, A.; Rayner, K. Chapter 15 - Eye movements in reading words and sentences. In; Van Gompel, R.P.G., Fischer, M.H., Murray, W.S., Hill, R.L.B.T.-E.M., Eds.; Elsevier: Oxford, 2007; pp. 341–371 ISBN 978-0-08-044980-7.
93. Choosing Colormaps in Matplotlib Available online: <https://matplotlib.org/stable/tutorials/colors/colormaps.html> (accessed on Sep 10, 2023).
94. Van Rossum, G.; Drake, F.L. *Python 3 Reference Manual*; CreateSpace: Scotts Valley, CA, 2009; ISBN 1441412697.
95. McKinney, W. Data Structures for Statistical Computing in Python. In Proceedings of the Proceedings of the 9th Python in Science Conference; van der Walt, S., Millman, J., Eds.; 2010; pp. 56–61.
96. Harris, C.R.; Millman, K.J.; van der Walt, S.J.; Gommers, R.; Virtanen, P.; Cournapeau, D.; Wieser, E.; Taylor, J.; Berg, S.; Smith, N.J.; et al. Array programming with NumPy. *Nature* **2020**, *585*, 357–362, doi:10.1038/s41586-020-2649-2.
97. Hunter, J.D. Matplotlib: A 2D graphics environment. *Comput. Sci. & Eng.* **2007**, *9*, 90–95.
98. Theiler, J. Estimating fractal dimension. *J. Opt. Soc. Am. A* **1990**, *7*, 1055–1073, doi:10.1364/JOSAA.7.001055.
99. Menard, S. *Applied logistic regression analysis*; Sage, 2002; ISBN 0761922083.
100. Kecman, V. Support Vector Machines – An Introduction BT - Support Vector Machines: Theory and Applications. In; Wang, L., Ed.; Springer Berlin Heidelberg: Berlin, Heidelberg, 2005; pp. 1–47 ISBN 978-3-540-32384-6.
101. Zhang, Z. Introduction to machine learning: k-nearest neighbors. *Ann. Transl. Med.* **2016**, *4*, 218, doi:10.21037/atm.2016.03.37.
102. Breiman, L. Random forests. *Mach. Learn.* **2001**, *45*, 5–32, doi:10.1023/A:1010933404324.
103. Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-learn: Machine Learning in {P}ython. *J. Mach. Learn. Res.* **2011**, *12*, 2825–2830.
104. Nembrini, S.; König, I.R.; Wright, M.N. The revival of the Gini importance? *Bioinformatics* **2018**, *34*, 3711–3718, doi:10.1093/bioinformatics/bty373.
105. Staub, A.; Benatar, A. Individual differences in fixation duration distributions in reading. *Psychon.*

Bull. Rev. **2013**, *20*, 1304–1311, doi:10.3758/s13423-013-0444-x.

106. Bott, N.T.; Lange, A.; Rentz, D.; Buffalo, E.; Clopton, P.; Zola, S. Web Camera Based Eye Tracking to Assess Visual Memory on a Visual Paired Comparison Task. *Front. Neurosci.* **2017**, *11*, doi:https://doi.org/10.3389/fnins.2017.00370.
107. Ferhat, O.; Vilariño, F. Low Cost Eye Tracking: The Current Panorama. *Comput. Intell. Neurosci.* **2016**, *2016*, 8680541, doi:10.1155/2016/8680541.
108. Lin, Z.; Liu, Y.; Wang, H.; Liu, Z.; Cai, S.; Zheng, Z.; Zhou, Y.; Zhang, X. An eye tracker based on webcam and its preliminary application evaluation in Chinese reading tests. *Biomed. Signal Process. Control* **2022**, *74*, 103521, doi:https://doi.org/10.1016/j.bspc.2022.103521.
109. Fuhl, W.; Rong, Y.; Kasneci, E. Fully Convolutional Neural Networks for Raw Eye Tracking Data Segmentation, Generation, and Reconstruction. In Proceedings of the 2020 25th International Conference on Pattern Recognition (ICPR); 2021; pp. 142–149.
110. Wu, Q.; Dey, N.; Shi, F.; Crespo, R.G.; Sherratt, R.S. Emotion classification on eye-tracking and electroencephalograph fused signals employing deep gradient neural networks. *Appl. Soft Comput.* **2021**, *110*, 107752, doi:https://doi.org/10.1016/j.asoc.2021.107752.
111. Deane, O.; Toth, E.; Yeo, S.-H. Deep-SAGA: a deep-learning-based system for automatic gaze annotation from eye-tracking data. *Behav. Res. Methods* **2023**, *55*, 1372–1391, doi:10.3758/s13428-022-01833-4.
112. Kohli, M.; Prasad, T. V Identifying dyslexic students by using artificial neural networks. In Proceedings of the Proceedings of the world congress on engineering; 2010; Vol. 1, pp. 1–4.
113. Zahia, S.; Garcia-Zapirain, B.; Saralegui, I.; Fernandez-Ruanova, B. Dyslexia detection using 3D convolutional neural networks and functional magnetic resonance imaging. *Comput. Methods Programs Biomed.* **2020**, *197*, 105726, doi:https://doi.org/10.1016/j.cmpb.2020.105726.
114. Li, Z.; Liu, F.; Yang, W.; Peng, S.; Zhou, J. A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Trans. Neural Networks Learn. Syst.* **2022**, *33*, 6999–7019, doi:10.1109/TNNLS.2021.3084827.
115. Gu, J.; Wang, Z.; Kuen, J.; Ma, L.; Shahroudy, A.; Shuai, B.; Liu, T.; Wang, X.; Wang, G.; Cai, J.; et al. Recent advances in convolutional neural networks. *Pattern Recognit.* **2018**, *77*, 354–377, doi:https://doi.org/10.1016/j.patcog.2017.10.013.
116. Lee, H.; Song, J. Introduction to convolutional neural network using Keras; an understanding from a statistician. *Commun. Stat. Appl. Methods* **2019**, *26*, 591–610, doi:10.29220/CSAM.2019.26.6.591.
117. Kim, P. Convolutional Neural Network BT - MATLAB Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence. In; Kim, P., Ed.; Apress: Berkeley, CA, 2017; pp. 121–147 ISBN 978-1-4842-2845-6.
118. Khan, A.; Sohail, A.; Zahoor, U.; Qureshi, A.S. A survey of the recent architectures of deep convolutional neural networks. *Artif. Intell. Rev.* **2020**, *53*, 5455–5516, doi:10.1007/s10462-020-09825-6.
119. Gu, J.; Wang, Z.; Kuen, J.; Ma, L.; Shahroudy, A.; Shuai, B.; Liu, T.; Wang, X.; Wang, G.; Cai, J.; et al. Recent advances in convolutional neural networks. *Pattern Recognit.* **2018**, *77*, 354–377,

doi:<https://doi.org/10.1016/j.patcog.2017.10.013>.

120. Shvetsova, N.; Bakker, B.; Fedulova, I.; Schulz, H.; Dyllov, D. V Anomaly Detection in Medical Imaging With Deep Perceptual Autoencoders. *IEEE Access* **2021**, *9*, 118571–118583, doi:10.1109/ACCESS.2021.3107163.
121. Patel, H.; Upla, K.P. A shallow network for hyperspectral image classification using an autoencoder with convolutional neural network. *Multimed. Tools Appl.* **2022**, *81*, 695–714, doi:10.1007/s11042-021-11422-w.
122. Zhang, H.; Xu, H.; Tian, X.; Jiang, J.; Ma, J. Image fusion meets deep learning: A survey and perspective. *Inf. Fusion* **2021**, *76*, 323–336, doi:<https://doi.org/10.1016/j.inffus.2021.06.008>.
123. Khamekhem Jemni, S.; Souibgui, M.A.; Kessentini, Y.; Fornés, A. Enhance to read better: A Multi-Task Adversarial Network for Handwritten Document Image Enhancement. *Pattern Recognit.* **2022**, *123*, 108370, doi:<https://doi.org/10.1016/j.patcog.2021.108370>.
124. Pawar, A. Noise reduction in images using autoencoders. In Proceedings of the 2020 3rd International Conference on Intelligent Sustainable Systems (ICISS); 2020; pp. 987–990.
125. Simonyan, K.; Zisserman, A. Very deep convolutional networks for large-scale image recognition. *arXiv Prepr. arXiv1409.1556* **2014**.
126. Martín~Abadi; Ashish~Agarwal; Paul~Barham; Eugene~Brevdo; Zhifeng~Chen; Craig~Citro; Greg~S.~Corrado; Andy~Davis; Jeffrey~Dean; Matthieu~Devin; et al. {TensorFlow}: Large-Scale Machine Learning on Heterogeneous Systems 2015.
127. Jiao, L.; Zhao, J. A Survey on the New Generation of Deep Learning in Image Processing. *IEEE Access* **2019**, *7*, 172231–172263, doi:10.1109/ACCESS.2019.2956508.
128. Gordon-Rodriguez, E.; Loaiza-Ganem, G.; Pleiss, G.; Cunningham, J.P. Uses and Abuses of the Cross-Entropy Loss: Case Studies in Modern Deep Learning. In Proceedings of the Proceedings on “I Can’t Believe It’s Not Better!” at NeurIPS Workshops; Zosa Forde, J., Ruiz, F., Pradier, M.F., Schein, A., Eds.; PMLR, 2020; Vol. 137, pp. 1–10.
129. Hintze, J.L.; Nelson, R.D. Violin Plots: A Box Plot-Density Trace Synergism. *Am. Stat.* **1998**, *52*, 181–184, doi:10.1080/00031305.1998.10480559.
130. Vajs, I.; Papić, T.; Ković, V.; Savić, A.M.; Janković, M.M. Accessible Dyslexia Detection with Real-Time Reading Feedback through Robust Interpretable Eye-Tracking Features. *Brain Sci.* **2023**, *13*.

15 Биографија



Иван Вајс је дипломирао 2019. године на Електротехничком факултету Универзитета у Београду, на смеру Сигнали и системи. Мастер студије је завршио на одсеку за Сигнале и системе истог факултета 2020. године. Докторске студије је започео 2020. године на Електротехничком факултету Универзитета у Београду, смер Управљање системима и обрада сигнала. Од 2019. године је запослен као истраживач у Иновационом центру Електротехничког факултета у Београду. У звање истраживач-приправник изабран је 26. новембра 2020. Његово истраживање је фокусирано на машинско учење и обраду сигнала у анализи биомедицинских података и калибрацији сензора. Бавио се истраживањима у области анализе хода користећи различите врсте мерења, као и примењеним когнитивним

истраживањима, анализирајући мултимодална сензорска мерења прикупљена од испитаника са дислексијом. Такође је радио са *low-cost* сензорима за мерење квалитета ваздуха, развијајући различите методе калибрације. Иван је аутор 12 научних публикација, од којих је 7 објављено у научним часописима импакт фактором, а 5 радова је објављено у зборницима са међународних конференција. Учествовао је у неколико истраживачких и комерцијалних пројеката, од којих је један међународни пројекат, Horizon2020 L4MS, "FOF-12-2017 ICT Innovation for manufacturing SMEs (I4MS), Area 2: Robotics", Грант #767642. Тренутно је део програма развоја науке и технологије Министарства просвете, науке и технолошког развоја „Подршка остваривању заједничког интереса у научноистраживачкој делатности“ и био је члан тима пројекта „Нова решења у развоју софтвера заснована на сличности текстова“ (*AVANTES*), који финансира Фонд за науку Републике Србије. Такође је учествовао у 3 пројекта за српске компаније: Дизајн и развој хибридне мреже за праћење квалитета ваздуха за фирму *DNET Labs*, Праћење спавања коришћењем радарске технологије и референтни мултимодални систем за фирму *Novellc*, оба суфинансирана од стране Фонда за иновациону делатност Републике Србије и курс Дигитална фабрикација – рад са 3Д штампачима за Бизнис инкубатор Ваљево.

Изјава о ауторству

Име и презиме аутора Иван Вајс

Број индекса 5014/2020

Изјављујем

да је докторска дисертација под насловом

Интелигентни системи за детекцију дислексичних образаца очних покрета током читања на српском језику

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио/ла интелектуалну својину других лица.

Потпис аутора

У Београду, 20.09.2023.

Иван Вајс

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора Иван Вајс

Број индекса 5014/2020

Студијски програм Управљање системима и обрада сигнала

Наслов рада Интелигентни системи за детекцију дислексичних образаца очних покрета током читања на српском језику

Ментор проф. др Милица Јанковић


Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла ради похрањивања у **Дигиталном репозиторијуму Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис аутора

У Београду, 20.09.2023.



Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Интелигентни системи за детекцију дислексичних образаца очних покрета током читања на српском језику

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.


Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство (CC BY)
- ☒ 2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци.
Кратак опис лиценци је саставни део ове изјаве).

Потпис аутора

У Београду, 20.09.2023.



1. **Ауторство.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. **Ауторство – некомерцијално.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. **Ауторство – некомерцијално – без прерада.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. **Ауторство – некомерцијално – делити под истим условима.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. **Ауторство – без прерада.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. **Ауторство – делити под истим условима.** Дозвољавање умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.