



УНИВЕРЗИТЕТ У НОВОМ САДУ
ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА У
НОВОМ САДУ



Драгана Ђорђевић Чегар

Моделовање утицаја 3Д видеа на квалитет доживљаја

- ДОКТОРСКА ДИСЕРТАЦИЈА -

Ментор:
проф. др Драган Кукољ

Нови Сад, 2021

УНИВЕРЗИТЕТ У НОВОМ САДУ
НАВЕСТИ НАЗИВ ФАКУЛТЕТА ИЛИ ЦЕНТРА

КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА¹

| | |
|---------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Врста рада: | Докторска дисертација |
| Име и презиме аутора: | Драгана Ђорђевић Чегар |
| Ментор (титула, име, презиме, звање, институција) | Др Драган Кукољ, редовни професор, Факултет техничких наука Универзитета у Новом Саду |
| Наслов рада: | Моделовање утицаја 3Д видеа на квалитет доживљаја |
| Језик публикације (писмо): | Српски (ћирилица) |
| Физички опис рада: | Унети број: Страница 137 Поглавља 10 Референци 110 Табела 21 Слика 22 Графикона 24 Прилога 0 |
| Научна област: | Електротехничко и рачунарско инжењерство |
| Ужа научна област (научна дисциплина): | Рачунарска техника и рачунарске комуникације |
| Кључне речи / предметна одредница: | Квалитет доживљаја, Вештачке Неуронске Мреже, Вишеслојни перцептрон, Машинско учење, дата мининг, откуцаји срца, електро-дермална активност, електро-енцефалограм, маникин за самопроцену, емоционално стање, стереоскопски 3Д видео, препорука садржаја, визуелна нелагодност |
| Резиме на језику рада: | Последњих година, очигледан је брз развој различитих медија у различитим сферама као што су потрошачка електроника, аутомобилска |

¹ Аутор докторске дисертације потписао је и приложио следеће Обрасце:
5б – Изјава о ауторству;
5в – Изјава о истоветности штапане и електронске верзије и о личним подацима;
5г – Изјава о коришћењу.

| | |
|-------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | <p>инфо-забава (енгл. Infotainment), софтвера у сврху здравства итд. Због тога намеће се потреба за иновативним методама процене квалитета доживљаја (енгл. Quality of Experience - QoE) које корисници доживљавају као замену за задовољство потрошача таквих системима и услугама. Емоционално стање корисника игра кључну улогу у области QoE; стога га је неопходно узети у обзир приликом процене корисничког искуства и процеса дизајнирања 3Д видео садржаја. У овој докторској дисертацији представљено је моделовање проценитеља квалитета доживљава заснованог на повратној вишеслојној вештачкој неуронској мрежи као одговарајућој техници машинског учења за процену човековог емоционалног стања током гледања различитих типова 3Д видео садржаја. Циљ је дизајнирање проценитеља емоционалног стања на основу директних психо-физиолошких мерења. Разматрани психо-физиолошки сигнали укључују срчану фреквенцију (HR) израчунату на основу ехо-кардиограма (ECG), електро-дермалну активност (EDA) и активност мозга (BA) у електро-енцефалографским (EEG) сигналима. Експериментални део истраживања постављен је тако да су учесници гледали серију 3Д видео садржаја који се разликују у погледу визуелног квалитета и типа садржаја, док су поменути психо-физиолошки сигнали забележени помоћу специјалних сонди постављених у моменту гледања садржаја, а субјективно проживљене емоције пријављене помоћу упитника за самопроцену (SAM). Добијени резултати показују да је могуће конструисати тако високо прецизан процењивач емоционалних стања.</p> |
| <p>Датум прихватања теме од стране надлежног већа:</p> | <p>17.07.2020.</p> |
| <p>Датум одбране: (Попуњава одговарајућа служба)</p> | |
| <p>Чланови комисије: (титула, име, презиме, звање, институција)</p> | <p>Председник: Др Никола Теслић, редовни професор, Факултет техничких наука Универзитета у Новом Саду Члан: Др Мирослав Поповић, редовни професор, Факултет техничких наука Универзитета у Новом Саду Члан: Др Вера Марковић, редовни професор, Електронски факултет Универзитета у Нишу Члан: Др Милан Бјелица, ванредни професор, Факултет техничких наука Универзитета у Новом Саду</p> |
| <p>Напомена:</p> | |

KEY WORD DOCUMENTATION²

| | |
|------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Document type: | Doctoral dissertation |
| Author: | Dragana Đorđević Čegar |
| Supervisor (title, first name, last name, position, institution) | PhD Dragan Kukolj, full professor, Faculty of Technical Sciences, University of Novi Sad |
| Thesis title: | Modelling the use of 3D video on the quality of experience |
| Language of text (script): | Serbian language (Cyrillic) |
| Physical description: | Number of: Pages 137 Chapters 10 References 110 Tables 21 Illustrations 22 Graphs 24 Appendices 0 |
| Scientific field: | Electrical and Computer Engineering |
| Scientific subfield (scientific discipline): | Computer engineering and communications |
| Subject, Key words: | Quality of Experience, Artificial Neural Network, Multi-Layer Perception, Machine Learning, Data mining, Heart Rate, Electro-dermal activity, Electroencephalogram, Self-Assessment Manikin, emotional state, S3D video, content recommendation, visual discomfort |
| Abstract in English language: | In recent years, the rapid development of diverse media has been evident in disparate fields such as consumer electronics, automotive infotainment and healthcare software. There is a need for innovative methods to assess user perceived Quality of Experience (QoE), as a proxy for consumer satisfaction with such systems and services. Users emotional state plays a key role in QoE; thus, it is necessary to consider it in user experience evaluation and the design process of stereoscopic 3D video content. In the PhD thesis the |

² The author of doctoral dissertation has signed the following Statements:
 56 – Statement on the authority,
 5B – Statement that the printed and e-version of doctoral dissertation are identical and about personal data,
 5r – Statement on copyright licenses.

| | |
|-------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | <p>use of a specially designed model based on a feedforward Multilayer Perception Artificial Neural Network as an appropriate Machine Learning technique for the estimation of human emotional state while viewing various categories of stereoscopic 3D video content is introduced. The goal is to design an emotional state estimator based on direct psychophysiological measurements. The considered psychophysiological signals include heart rate (HR) calculated from an echocardiogram (ECG), electro-dermal activity (EDA), and brain activity (BA) in EEG signals. In the experimental part of study, participants watched a series of 3D video contents varying in terms of visual quality and type of content, while the mentioned psychophysiological signals were recorded via specific equipment, and self-reported subjectively experienced emotions using a Self-Assessment Manikin (SAM) questionnaire. The obtained results show that it is possible to construct such a highly precise estimator of emotional states.</p> |
| Accepted on Scientific Board on: | 17.07.2020. |
| Defended: (Filled by the faculty service) | |
| Thesis Defend Board: (title, first name, last name, position, institution) | <p>President: PhD Nikola Teslić, full professor, Faculty of Technical Sciences, University of Novi Sad</p> <p>Member: PhD Miroslav Popović, full professor, Faculty of Technical Sciences, University of Novi Sad</p> <p>Member: PhD Vera Marković, full professor, Electronic Faculty, University of Niš</p> <p>Member: PhD Milan Bjelica, associate professor, Faculty of Technical Sciences, University of Novi Sad</p> |
| Note: | |

ЗАХВАЛНИЦА

Од срца се захваљујем свом ментору, професору доктору Драгану Кукољу, на сугестијама, усмеравању и подршци у мом раду, а пре свега знању које сам несебично добила од њега.

Велику захвалност дугујем професору доктору Николи Теслићу, наставном кадру и колективу РТ-РК Института што су ми омогућили да свој сан претворим у стварност и крунишем дисертацијом.

Највећу захвалност, ипак, дугујем својим родитељима и сестри који су ме подржавали од почетка мог пута образовања, као и супругу Јовану који ме је морално подизао у свим изазовним тренуцима.

Рад посвећујем свом сину Растку.

Резиме докторске дисертације

Последњих година, очигледан је брз развој различитих медија у различитим сферама као што су потрошачка електроника, аутомобилска инфо-забава (енгл. *Infotainment*), софтвера у сврху здравства итд. Због тога намеће се потреба за иновативним методама процене квалитета доживљаја (енгл. *Quality of Experience - QoE*) које корисници доживљавају као замену за задовољство потрошача таквих системима и услугама. Емоционално стање корисника игра кључну улогу у области QoE; стога га је неопходно узети у обзир приликом процене корисничког искуства и процеса дизајнирања 3Д видео садржаја. У овој докторској дисертацији представљено је моделовање проценитеља квалитета доживљава заснованог на повратној вишеслојној вештачкој неуронској мрежи као одговарајућој техници машинског учења за процену човековог емоционалног стања током гледања различитих типова 3Д видео садржаја. Циљ је дизајнирање проценитеља емоционалног стања на основу директних психо-физиолошких мерења. Разматрани психо-физиолошки сигнали укључују срчану фреквенцију (HR) израчунату на основу ехокардиограма (ECG), електро-дермалну активност (EDA) и активност мозга (BA) у електроенцефалографским (EEG) сигнаlima. Експериментални део истраживања постављен је тако да су учесници гледали серију 3Д видео садржаја који се разликују у погледу визуелног квалитета и типа садржаја, док су поменути психо-физиолошки сигнали забележени помоћу специјалних сонди постављених у моменту гледања садржаја, а субјективно проживљене емоције пријављене помоћу упитника за самопроцену (SAM). Добијени резултати показују да је могуће конструисати тако високо прецизан процењивач емоционалних стања.

Summary of doctoral thesis

In recent years, the rapid development of diverse media has been evident in disparate fields such as consumer electronics, automotive infotainment and healthcare software. There is a need for innovative methods to assess user perceived Quality of Experience (QoE), as a proxy for consumer satisfaction with such systems and services. Users emotional state plays a key role in QoE; thus, it is necessary to consider it in user experience evaluation and the design process of stereoscopic 3D video content. In the PhD thesis the use of a specially designed model based on a feedforward Multilayer Perception Artificial Neural Network as an appropriate Machine Learning technique for the estimation of human emotional state while viewing various categories of stereoscopic 3D video content is introduced. The goal is to design an emotional state estimator based on direct psychophysiological measurements. The considered psychophysiological signals include heart rate (HR) calculated from an echocardiogram (ECG), electro-dermal activity (EDA), and brain activity (BA) in EEG signals. In the experimental part of study, participants watched a series of 3D video contents varying in terms of visual quality and type of content, while the mentioned psychophysiological signals were recorded via specific equipment, and self-reported subjectively experienced emotions using a Self-Assessment Manikin (SAM) questionnaire. The obtained results show that it is possible to construct such a highly precise estimator of emotional states.

Садржај

| | | |
|-------|---------------------------------------------------------------------------------|----|
| 1 | Увод..... | 1 |
| 1.1 | Предмет истраживања..... | 1 |
| 1.2 | Мотивација и циљ истраживања..... | 2 |
| 1.3 | Научни допринос..... | 4 |
| 1.4 | Организација дисертације..... | 6 |
| 2 | Стање у области..... | 9 |
| 2.1 | Стање области квалитета доживљаја..... | 9 |
| 2.2 | Преглед истраживања корелације психо-физиолошких мера и квалитета доживљаја | 12 |
| 2.3 | Преглед модела за процену и предвиђање емоционалног стања и квалитета доживљаја | 13 |
| 3 | Квалитет доживљаја..... | 16 |
| 3.1 | Дефиниција квалитета доживљаја..... | 16 |
| 3.2 | Фактори утицаја на квалитет доживљаја..... | 18 |
| 3.3 | Квалитет доживљаја 3Д видео садржаја..... | 21 |
| 3.3.1 | Кориснички фактори утицаја 3Д - Фактори перцепције корисника..... | 22 |
| 3.3.2 | Ефекти услед системских фактора утицаја на 3Д..... | 23 |
| 4 | Мерење квалитета доживљаја..... | 27 |
| 4.1 | Дводимензионални модел емоционалних стања..... | 27 |
| 4.2 | Објективне мере..... | 29 |
| 4.3 | Субјективне мере..... | 34 |

| | | |
|-------|--------------------------------------------------------------------------------|----|
| 5 | База података | 39 |
| 5.1 | Опис базе видео материјала..... | 39 |
| 5.2 | Поставка експерименталног снимања | 41 |
| 6 | Преглед употребљених алгоритама | 46 |
| 6.1 | Вештачке неуронске мреже | 46 |
| 6.1.1 | Перцептрон правило обуке..... | 49 |
| 6.1.2 | Делта правило обуке | 50 |
| 6.1.3 | Вишеслојни перцептрон | 51 |
| 6.1.4 | <i>Levenberg–Marquardt</i> алгоритам..... | 54 |
| 6.2 | Неуронске мреже са општом регресијом | 55 |
| 6.3 | Метод регресије потпорних вектора - <i>Support Vector Regression SVR</i> | 57 |
| 6.4 | Редукција димензије модела..... | 59 |
| 6.4.1 | Анализа базних компоненти | 60 |
| 6.5 | Пеарсон и Спепарман корелација | 61 |
| 7 | Метода и фазе истраживања | 65 |
| 7.1 | Припрема необрађених података и филтрирање..... | 67 |
| 7.2 | Издвајање обележја | 68 |
| 7.3 | Развој и анализа проценитеља емоционалног стања | 70 |
| 7.3.1 | Одабир обележја..... | 70 |
| 7.3.2 | Поставка неуронске мреже..... | 72 |
| 8 | Резултати и дискусија..... | 77 |
| 8.1 | Упоредна анализа | 77 |
| 9 | Закључак | 92 |

| | | |
|----|--------------------------------------------------|-----|
| 10 | Радови које претходе докторској дисертацији..... | 96 |
| 11 | Литература..... | 104 |
| 12 | Спољње везе..... | 115 |
| | План третмана података..... | 116 |

СПИСАК СЛИКА

| | |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Слика 1 – Процес формирања квалитета на основу [91]..... | 17 |
| Слика 2 – Подела фактора утицаја | 19 |
| Слика 3 - Фактори утицаја на квалитет доживљаја | 20 |
| Слика 4 – Основна обележја 3Д квалитета доживљаја [69]..... | 21 |
| Слика 5 – Обрада и пренос 3Д видео садржаја | 23 |
| Слика 6 – Компоненте емоција и њихов утицај на процес стварања | 27 |
| Слика 7 - Дводимензионални простор емоција [3]..... | 28 |
| Слика 8 – Пример промене GSR код субјекта 7 током конзумирања мирног видеа „Lake” | 30 |
| Слика 9 – Поставка електрода приликом мерења а) ECG б) EDA в) EEG..... | 30 |
| Слика 10 - ECG сигнал | 32 |
| Слика 11 – Делови мозга – светло плаво чеони режањ, наранцасто темени режањ, зелено слепоочни режањ, розе потиљачни режањ | 33 |
| Слика 12 – а) Континуална скала и б) компаративна скала..... | 35 |
| Слика 13 - Self-Assessment Manikin скала са 9 нивоа оцена за узбуђење и задовољство | 36 |
| Слика 14 – Приказ сцена видеа Типа 1, Типа 2 и Типа 3 респективно (с лева на десно) [5] [99][100] | 39 |
| Слика 15 – Пример сцена са визуалном nelaгодности [5][100] | 40 |
| Слика 16 – Нелинеарни модел неурона | 46 |
| Слика 17 – Активационе функције а) праг функција, б) изломљена линеарна функција, в) логистичка функција г) тангенс хиперболична функција д) Гаусова (радијално базна) функција | 47 |
| Слика 18 - Архитектура неуронских мрежа а) једнослојне б) вишеслојне и в) рекурентне неуронске мреже | 48 |
| Слика 19 – Пример вишеслојног перцептрона..... | 52 |
| Слика 20 - Формулација SVR из геометријске перспективе | 58 |
| Слика 21 – Кораки методе анализе независних компоненти | 60 |
| Слика 22 - Степ дијаграм предложене методологије | 66 |

| | |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Слика 23 MLP конфигурација са HR и EDA одабраним карактеристикама као улазом | 73 |
| Слика 24 MLP конфигурација са EEG одабраним карактеристикама као улазом | 74 |
| Слика 25 – Графички приказ Табеле 10 | 78 |
| Слика 26– Графички приказ Табеле 11 | 79 |
| Слика 27– Графички приказ Табеле 12 | 80 |
| Слика 28 – Графички приказ Табеле 13 | 81 |
| Слика 29 – Графички приказ Табеле 14 | 81 |
| Слика 30 (лево) Корен средње квадратне вредности за све HR улазе и све EDA улазе за скалу узбуђења и задовољства | 82 |
| Слика 31 (десно) Пеарсон корелациони коефицијент за HR улазе и све EDA улазе за скалу узбуђења и задовољства | 82 |
| Слика 32 (лево) Спирман корелациони коефицијент за HR улазе и све EDA улазе за скалу узбуђења и задовољства | 82 |
| Слика 33 (десно) Стандардна девијација за HR улазе и све EDA улазе за скалу узбуђења и задовољства | 82 |
| Слик 34 - Графички приказ Табела 17 (лево) и 18 (десно) | 85 |
| Слик 35 - Графички приказ Табела 19 (лево) и 20 (десно) | 86 |
| Слика 36 Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) мирног видеа | 87 |
| Слика 37 Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) средње умереног видеа | 87 |
| Слика 38 - Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) веома узбудљивог видеа | 88 |
| Слика 39 – а) Оцене забележе упитником (горе лево); б) Процењена оцена најбољег проценитеља HR и EDA модела (горе десно); в) Процењена оцена просечног проценитеља за обележје HR Median (доле лево); г) Процењена оцена најлошијег проценитеља за обележје EDA PCA (доле десно) | 89 |

СПИСАК ТАБЕЛА

| | |
|-----------------------------------------------------------------------------------------------------------|----|
| Табела 1 - Мождани таласи..... | 33 |
| Табела 2 – Пример варијације визуелне нелагодности за различите учеснике | 41 |
| Табела 3 - Оцене субјеката за видео мирног садржаја | 42 |
| Табела 4 - Оцене субјеката за видео умерено активног садржаја | 43 |
| Табела 5 - Оцене субјеката за видео хорор садржаја..... | 43 |
| Табела 6 - списак свих издвојених обележја за HR и EDA..... | 68 |
| Табела 7 - списак свих издвојених обележја за EEG | 69 |
| Табела 8 – Одабрана обележја модела HR/EDA | 71 |
| Табела 9 – Одабрана обележја модела EEG | 72 |
| Табела 10 MLP, GRNN и SVR проценитељи са свим HR и EDA улазима..... | 78 |
| Табела 11 Проценитељ узбуђења MLP са појединачним улазним обележјима..... | 79 |
| Табела 12 Проценитељ задовољства MLP са појединачним улазним обележјима | 80 |
| Табела 13 Проценитељи MLP и GRNN са свим улазима HR обележјима | 80 |
| Табела 14 Проценитељ MLP и GRNN са свим улазима EDA обележјима..... | 81 |
| Табела 15 Проценитељ узбуђења комбинација са два HR и EDA улаза | 83 |
| Табела 16 Проценитељ задовољства комбинација са два HR и EDA улаза..... | 84 |
| Табела 17 Проценитељ са свим EEG обележјима као улазима | 84 |
| Табела 18 Проценитељ са свим EEG обележјима у потиљачном и чеоном режњу као улазима | 84 |
| Табела 19 Проценитељ са свим EEG обележјима у потиљачном режњу као улазима за сва медијана обележја | 85 |
| Табела 20 Проценитељ са свим EEG обележјима у теменом режњу као улазима за сва медијана обележја..... | 85 |
| Табела 21 Проценитељ са појединачним обележјима (EEG медијана) за 1) узбуђење и 2) задовољство | 86 |

СКРАЋЕНИЦЕ И ПОЈМОВИ

| | |
|----------|--------------------------------------------------------------------------------|
| ACR-HR | Absolute Category Rating with Hidden Reference |
| ANN | Artificial Neural Network |
| BA | Brain Activity |
| BeEM | Bio-emotion Estimate Method |
| CCRF | Continuous Conditional Random Fields |
| COST | European Cooperation in Science and Technology |
| CMOS | Comparison Mean Opinion Score |
| DMOS | Difference Mean Opinion Score |
| DSIS | Stimulus Impairment Scale |
| ECG | electrocardiograph |
| EDA | electro dermal activity |
| EEG | electroencephalograph |
| GRNN | General Regression Neural Network |
| GSP | Galvanic Skin Potential |
| GSR | galvanic skin response |
| HR | Heart rate |
| HRV | Hart Rate Variability |
| HTTP | Hypertext Transfer Protocol |
| ITU-T | International Telecommunication Union Telecommunication Standardization Sector |
| IP TV | Internet Protocol television |
| LSTM-RNN | Long-short-term-memory recurrent neural networks |
| MLP | Multilayer Perceptron |
| MOS | Mean Opinion Score |
| MPEG | Moving Picture Experts Group |
| PCA | Principal Component Analysis |
| QoE | Quality of Experience |
| QoS | Quality of Service |
| SAM | Self-Assessment Manikin |
| SC | Stimulus Comparison |
| SCL | Skin Conductance Level |
| SRC | Skin Conductance Response |
| SS | Single Stimulus |
| SSCQE | Single Stimulus Continuous Quality Evaluation |
| SVM | Supporting Vector Machine |
| SVR | Supporting Vector Machine for Regression |
| VoIP | Voice over IP |

1 Увод

1.1 Предмет истраживања

Због веома брзих промена у области потрошачке електронике, софтвера за здравствену заштиту, као и информационо-забавног програма за телевизију или аутомобиле, усмерених на задовољство корисника, развој разних апликација и препорука садржаја у истраживањима везаним за квалитет доживљаја (енгл. *Quality of Experience QoE*) су наша садашњост и готово неизвесно наша будућност. С обзиром на чињеницу да емоционална стања, један од фактора утицаја на квалитет доживљаја, играју важну улогу у конзумирању видео садржаја, потребно их је укључити у процес процене корисничког искуства и процес дизајнирања видео садржаја. Како би се испитале многобројне могућности које ова област пружа, те употребило већ постојеће знање из области психо-физиолошких истраживања, анализе података (енгл. *Data mining*) и машинског учења, предмет рада базира се на моделовању утицаја мултимедијалног садржаја на квалитет доживљаја. Као избор мултимедијалног садржаја употребљен је 3Д видео садржај због своје природе, која захтева квалитетну обраду, припрему и прилагођавање корисничком доживљају.

Процена корисничког доживљаја и мерење квалитета истог, посредством праћења тренутног емоционалног стања, могу се постићи само субјективним тестирањем и објективним мерењем реалних параметара људског тела. Ово истраживање има за циљ да уведе употребу специјално дизајнираног модела на бази технике машинског учења за процену доживљаја корисника приликом посматрања различитих категорија 3Д видео садржаја.

Психо-физиолошки сигнали мерени у реалним условима, употребљени као референтни подаци у раду, укључују електро-кардиографски сигнале, у даљем тексту ECG (енгл. *electrocardiograph ECG*) у облику срчане фреквенције (енгл. *Heart Rate HR*), електро-дермалну активност, у даљем тексту EDA (енгл. *electro dermal activity EDA*) и моздану активност у облику електро-енцефалографских сигнала (енгл. *electroencephalograph EEG*), у даљем тексту EEG. У сврху валидације модела прикупљене су и субјективне оцене у форми дводимензионалне скале узбуђења и задовољства помоћу упитника за само процену. Основни циљ је креирање процене квалитета доживљаја на основу директних мерења

људских параметара уместо употребе субјективних резултата. Осим потребе за моделовањем квалитета доживљаја, овим истраживањем се жели испитати утицај садржаја на емоционално стање, као и утицај техничког квалитета (оштећења) садржаја на емоционално стање.

Генерална хипотеза истраживања је да се може изградити не персонализовани модел процене квалитета доживљаја који може да процени степен задовољства корисника при гледању различитих типова мултимедијалног садржаја на основу узорка снимљеног био сигнала, из којег се извлаче претходно изабрани специфични параметри. Један од аспеката предмета истраживања је генерализација процеса, уштеда капацитета меморије и убрзавање покретања софтверских апликација за препоруку садржаја. Такође, циљ је да предложена методологија укаже да адекватним избором технике машинског учења за процену емоционалног стања заснованог на објективним мерама у облику психо-физиолошких сигнала, можемо доћи до завидне прецизности процене емотивног стања, једног од фактора квалитета доживљаја. Дакле, фокус истраживања није на методи машинског учења, већ моделовању квалитета доживљаја и утицају садржаја на емотивно стање корисника, тачније процени квалитета доживљаја, у сврху употребе у софтверским апликацијама за процену.

Предмет истраживања дат је кроз излагање проблема, циљеве, методе који су употребљени, план рада са фазама истраживања, као и дискусију о резултатима и могућим применама резултата.

1.2 Мотивација и циљ истраживања

Људске емоције могу се сматрати кључним „наредбама акција“ за одређивање адаптивног понашања у датом окружењу [42]. Емоције се схватају као психолошки конструктори који се манифестују кроз три система одговора, укључујући: субјективне перцепције, психо-физиолошке реакције и понашање [6], који нису увек у потпуној корелацији. Стога, у циљу добијања тачних информација о томе како ће корисник емоционално реаговати према одређеној стимулацији, није довољан субјективни одговор корисника. С тим у вези, психо-физиолошке мере, односно мере физиолошких варијабли које указују на психолошке процесе, имају велики значај [43].

Међутим, добијање тачне слике о емоционалном стању корисника мултимедијског садржаја није једноставан процес. Када се сматрају представницима менталног стања, психо-физиолошки сигнали су прилично зашумљени, јер на њих не утичу само ментални

процеси, већ и нормалне функције тела [44]. Да би се зашумљеност свела на минимум и истакао информативни потенцијал психо-физиолошких сигнала, велики значај имају вишедимензионални приступи који укључују различите врсте психо-физиолошких сигнала.

Штавише, велика индивидуална варијабилност психо-физиолошких реакција сугерише потребу за разматрањем различитих група људи који зависе од старости, пола и образовања и употребе таквих података за изградњу персонализованих модела. Међутим, у пракси је капацитет меморије уређаја инсталираних у аутомобилима, паметним кућама или другим паметним уређењима доступним на тржишту веома лимитиран. Затим, време калибрације уређаја и прилагођавање на персонализоване моделе могу бити огромна препрека приликом употребе паметних опција за предвиђање или препоруку, што указује да је неопходно пронаћи начин да се моделују не-персонализовани модели.

Снимање и праћење психо-физиолошких сигнала у стварним условима може бити врло захтеван процес. Једно од ограничења може бити потреба за употребом специјализованих уређаја за надгледање и снимање таквих сигнала. Готово је сигурно да већина корисника не жели да носи паметан сат или држи даљински управљач како би надгледали свој пулс или електро дермалну активност. Чак и мобилни уређаји или мали носиоци сензора могу неким корисницима створити непријатности. Даље, још већу непријатност могу да произведу уређаји за мерење можданих активности јер се морају носити на глави. Претпоставка је да се ова ограничења не могу лако избећи у будућности, осим за кориснике који би могли да имају здравствену бенефит приликом мерење параметара за контролу садржаја (нпр. особе које болују од епилепсије те су осетљиве на брзу промену боја, проблем са срцем приликом интензивних сцена итд.) и који би се могли прилагодити одређеним функцијама паметних сатова или паметних рукавица.

Мотивација за истраживањем је верификовање да се на основу снимљених психо-физиолошких узорака сигнала из којих су пажљиво изабрани специфични параметри може изградити не-персонализован модел. Овај модел не само да може уштедети капацитет меморије складиштења и убрзати покретање софтверских апликација и препоруке садржаја, већ омогућити генерализацију процеса. Генерализација процеса отвара неограничене могућности употребе модела на бази техника машинске интелигенције у процени квалитета доживљаја.

Приликом истраживања испитане су могућности различитих техника машинског учења, а коначни излази предложених модела дали су назнаку да је изабрана и адекватна

техника за процену емоционалног стања на основу објективних мера у виду психофизиолошких сигнала.

1.3 Научни допринос

Општи допринос докторске дисертације огледа се у спајању више научних дисциплина у сврху побољшања угођаја корисника мултимедијалног садржаја. Основна идеја овог рада да се дизајнира процењивач квалитета доживљаја 3Д видео записа на основу директних мерења људских параметара без субјективне процене, није још увек довољно истражена тема која отвара потпуно нову област истраживања. Област омогућује мултидисциплинарност, велики број варијабли и међузависности које нису довољно испитане заједно. Као резултат мултидисциплинарности, истраживање приказано у овој докторској дисертацији односи се на предлог модела за предвиђање емоционалног стања људи приликом конзумирања 3Д видео садржаја како би се на основу добијеног предвиђања оценио квалитет доживљаја. Предвиђање емоционалног стања људи као фактора који утиче на квалитет доживљаја, потребно нам је како би се субјективни доживљај приказаног 3Д видео могао искористити у сврху побољшања дизајна 3Д видео, препоруке видео садржаја, као и предвиђања потенцијалних нелагодности које могу изазвати здравствене проблеме корисника. Такође, овакви проценитељи могу помоћи да се неки видео садржај у реалном времену може ограничити у зависности од предвиђеног понашања корисника. Пример ограничавања је филтрирање делова видео садржаја који неповољно утичу на људе са угроженим радом срца, епилепсијом и сличним тегобама.

Методологија истраживања укључује анализу неколико техника за машинско учење и техника за припрему и претрагу улазних података у сврху проналажења најбољих проценитеља. Варијација улазних параметара и техника машинског учења доприносе упоредној анализи која може бити корисна референца даљим истраживањима у области. Моделовање квалитета доживљаја уз помоћ техника машинског учења и формализације приступа употребом теоријског концепта и статистичких метода део су општег доприноса докторске дисертације. У раду се испитују и технике издвајања и избора обележја психофизиолошких података за процесирање емоционалног стања, које се не користе у претходно објављеним радовима као улазни подаци вештачких неуронских мрежа (енгл. *Artificial Neural Networks ANN*).

Начини моделовања приказани у раду представљају специфични научни допринос у области истраживања. Намера је да се покаже како се поуздана процена емоционалних стања повезаних са стероскопским видео садржајем може постићи без потребе за персонализацијом модела процеса, што уноси новину у истраживањима процене квалитета доживљаја на бази психо-физиолошких параметара. Ови не персонализовани модели могу се добити само детаљном анализом различитих врста видео записа у погледу узбуђења (енгл. *Arousal*) и задовољства (енгл. *Valence*).

Због природе 3Д видеа, који у великом броју случајева доноси nelaгоду кориснику, испитано је и како се мења понашање модела приликом уношења техничког оштећења видео секвенци. Промена квалитета приказивања 3Д видео садржаја допринела је да се испита моментална промена емоционалног стања и доживљаја садржаја на квалитет приказивања, што је допринело да база података снимљена приликом експерименталног поступка има непроцењиву вредност и јединственост. Поред основне хипотезе да се могу направити поменути модели, постављена је и хипотеза да ће људи бити несретнији ако је дисторзија већа, односно повећаће се визуелна непријатност.

Овај рад разрађује мноштво модела анализирањем утицаја различитих видео садржаја, праћења параметара прикупљених са ECG, EDA и EEG, који нису упоредно испитивани у претходно објављеним радовима. Истраживање је фокусирано на проналажењу оптималног броја улазних параметара и природе улаза у односу на грешку процене. Упоредна анализа дизајна модела је централни део истраживања.

На основу претходно описаног научни допринос се може поделити на неколико кључних аспеката:

- дизајнирање процењивача квалитета доживљаја 3Д видео записа на основу директних мерења људских параметара без субјективне процене;
- моделовање квалитета доживљаја уз помоћ техника машинског учења;
- издвајање и одабир обележја психо-физиолошких података за процесирање емоционалног стања;
- дефинисање не-персонализованог модела;
- испитивање утицаја визуелне nelaгоде на у виду дисторзије на квалитет доживљаја;
- употреба комбинације ехо кардиограф у облику срчане фреквенције, електро дермалне активности и мождане активности у облику електро-енцефалограмних сигнала.

У току рада на овом истраживању објављен је рад у престижном научном часопису, патентна пријава, седам радова на међународним конференцијама и још неколицина са домаћих конференција који су излистани у поглављу „Референце које претходе докторској дисертацији“.

Рад је производ размене знања *Истраживачко-развојног института РТ-РК* са члановима *COST European Cooperation in Science and Technology* у оквиру две акције:

- *Qualinet COST IC1003 – European Network on Quality of Experience in Multimedia Systems and Service [a]* кроз летњу школу „*2nd Qualinet Summer School on Crowdsourcing and QoE Assessment*“ у организацији *University of Würzburg, Germany* и *University of Patras, Greece* и радова у оквиру QoMEX међународних конференција;
- *COST Action IC1105 3D-ConTourNet [b]* кроз „*Short-Term Scientific Missions Modeling of the effects of 3D visual discomfort to human emotional state using data mining technique*“ у организацији *Polytech Nantes/Université de Nantes IRCCYN/IVC, France*.

1.4 Организација дисертације

Рад је подељен у десет логичких целина. Прво поглавље „Увод“ описује предмет, циљ и мотивацију, као и научни допринос овог истраживања. Идеја је да се у првом поглављу детаљно резимира избор научне области и допринос рада.

Друго поглавље „Стање у области“ разматра актуелна истраживања квалитета доживљаја, затим корелације емоционалног стања и квалитета доживљаја, субјективних мера у сврху процене квалитета доживљаја, као и различитих техника машинског учења на многобројним скуповима података, која су била полазна основа за истраживање у овом раду.

Мултидисциплинарност овог истраживања намеће потребу за детаљним излагањем дефиниције квалитета доживљаја, те се у наставку, у поглављу „Квалитет доживљаја“, детаљно описује комплексности и повезаности са дводимензионалним моделом емоционалних стања.

Поглавље „Мерење квалитета доживљаја“ дефинише објективне и субјективне мере употребљене приликом експерименталног дела истраживања. Даље, објашњене су методе мерења субјективних и објективних мера.

У наставку, поглављу „База података“, је представљен ток експерименталног снимања и прикупљање базе података. Детаљно је описано оцењивање и опис видео материјала који је био употребљен у раду.

У „Преглед употребљених алгоритама“ дефинисано је неколико употребљених обука са надзором (енгл. *Supervised learning*) у сврху разумевања упоредне анализе приказане употребом алгоритама:

- енгл. *Multilayer Perceptron* (у даљем тексту *MLP*);
- енгл. *General Regression Neural Network* (у даљем тексту *GRNN*) и
- енгл. *Support Vector Machine for Regression* (у даљем тексту *SVR*).

Осим техника машинског учења, у овом поглављу, дат је и преглед осталих употребљених статистичких метода и алгоритама.

Као кључни део дисертације издвојене су две целине, „Предлог методологије и фазе истраживања“ и „Резултати и дискусија“. Поглавље „Метода и фазе истраживања“ описује припремну фазу методе у виду необрађених података и издвајању обележја, као и развој и анализу проценитеља емоционалног стања кроз одабир обележја и техника машинског учења. Упоредна анализа и детаљна дискусија дата је у наставку.

Рад се завршава коначним „Закључком“ који је донесен на основу претходне упоредне анализе и дискусије. Фазе описане дијаграмом тока, у кључном делу дисертације, део су истраживања описаних у радовима који су објављени на домаћим и иностраним конференцијама, а детаљан списак дат је у поглављу „Референце које претходе докторској дисертацији“.

2 Стање у области

2.1 Стање области квалитета доживљаја

Термин квалитет доживљаја (енгл. *Quality of Experience QoE*) предмет је многих истраживања у области мултимедијалних комуникационих система иако се не ограничава само на ову област. Премда детаљно истраживана од касних 90тих година, још увек актуелна тема, квалитет доживљаја добио је темеље и своју најприхватљивију дефиницију у документацији [37] 2013. године у оквиру *COST Qualinet* акције. Под сада званичном ознаком ITU-T P.10, квалитет доживљаја изашао је коначно из сенке квалитета сервиса (енгл. *Quality of Service QoS*), са којим је често био заједно разматран.

Иако дефинисан и истраживан, квалитет доживљаја је и даље недовољно испитана област истраживања. Управо због тога квалитет доживљаја и даље има небројено дефиниција у зависности од области и контекста у коме се спомиње. Дефинисање квалитета доживљаја дато је у поглављу „Дефиниција квалитета доживљаја“, а веома значајан преглед тренутно доступних дефиниција дат је у [65].

Од самог почетка дефинисања ове области наметнули су се изазови и правци истраживања као што су:

- Фактори утицаја на квалитет доживљаја;
- Менаџмент квалитета доживљаја;
- Типологија и систематика квалитета доживљаја;
- Процена квалитета разних типова садржаја (аудиовизуелног, 2Д, 3Д, виртуелне реалности, видео игрица итд.);
- Стандардизација и сертификација квалитета доживљаја;
- Утицај психологије на квалитет доживљаја;
- Повезаност просечне оцене мишљења (енгл. *Mean Opinion Score*) и квалитет доживљаја;
- *Crowdsourcing*;
- Квалитет доживљаја приликом препознавања говора;
- Повезаност физиолошких параметара корисника и квалитета доживљаја;
- Мерење квалитета доживљаја;
- Машинско учење у сврху квалитета доживљаја;

- Моделовање квалитета доживљаја;
- Квалитет доживљаја усмерен на податке;
- Мулсмедиа и квалитет доживљаја;
- Квалитет доживљаја и медицина (корисника са здравственим проблемима);
- Квалитет доживљаја широкопојасних мрежа.

У зависности од фактора утицаја на квалитет доживљаја, груписаних у корисничке, системске (техничке природе) и контекстуалне, може се приметити да тренутна истраживања имају различите приступе моделовања квалитета доживљаја. Значајан помак у систематизацији и разумевању фактора утицаја на квалитет доживљаја дали су аутори [66] обрађујући топологију квалитета доживљаја осврћући се на све системске факторе утицаја и то посебно моделујући приступ за употребу у енгл. *Voice on demand* и енгл. *Mobile TV* домену. На сличан начин истраживање [72] моделује квалитет доживљаја узимајући у обзир само факторе утицаја уређаја и мреже у области енгл. *IP television*. У домену употребе мултимедијалних сервиса, у раду [73] поред системских сагледани су и фактори утицаја контекста у коме се садржај употребљава. Даље, истраживање [74] осим поменутих системских и контекстуалних фактора утицаја приликом употребе у мултимедијалном домену укључује и факторе корисничког знања. Са друге стране истраживања [75] и [76] осврћу се на све познате факторе утицаја при чему обрађују видео и Интернет употребу, респективно.

Управљање квалитетом доживљаја од изузетне је важности за мултимедијалне сервисе како би се привукла пажња крајњег корисника на одређени садржај. У литератури предложено је неколико решења за управљање мрежом и управљање пропусним опсегом усмереним на квалитет доживљаја, која имају за циљ побољшање квалитета доживљаја испорученог крајњим корисницима. Посебан осврт на управљање квалитетом доживљаја у области енгл. *Cloud Applications* дат је у [88]. Даље, управљање квалитетом доживљаја у *Wireless* мрежама [89] и *HTTP Adaptive Streaming* [90] добар су примери од колике је важности ова тематика. У литератури обрађен је и фактор правичности управљања квалитетом доживљаја [39] као једим од битних аспеката управљања у сврху задовољства крајњег корисника на правичан начин.

Многи аутори покушали су да направе јасну разлику између квалитета сервиса и квалитета доживљаја анализом њихове области деловања и њихове повезаности. Аутори [52] и [87] детаљно обрађује овај проблем. Напори да се квалитет доживљаја стандардизује

и да се сертифицикују методи који претходе евалуацији квалитета доживљаја део су мноштва истраживања при чему се дефиниција мењала у зависности од контекста употребе. На основу ITU-T Rec. P.10 (*Amendment 2, 2008*) [85] квалитет доживљаја описан је као „Укупна прихватљивост апликације или услуге, коју крајњи корисник субјективно доживљава“ што није у потпуности прихваћено од стране научне јавности па је потрага за бољом дефиницијом и стандардизацијом настављена кроз [78], [86] и [37] итд.

Од посебног значаја за истраживање описано овом дисертацијом је улагање напора у сертификацију 3Д квалитета доживљаја и његову процену. Тако истраживање [55] представља рани покушај дефинисања процеса за сертификацију тест метода, на основу унакрсне валидације резултата испитивања у различитим лабораторијама са крајњим циљем званичне сертификације квалитета доживљаја. Прецизније, неколико европских лабораторија кроз истраживање покушало је да да темеље сертификације кроз дискусију случаја процене 3Д видео компресије у оквиру MPEG дефиниције стандарда за кодовање 3Д видео записа.

Детаљна анализа процене квалитета доживљаја 3Д видео садржаја дата је у [53], при чему се аутор не осврће само на процену већ и на начин на који такав садржај настаје укључујући све техничке аспекте: продукцију, пренос, кодовање, приказ итд. Техничке аспекте дају даље, аутори [83] кроз емпиријску студију за процену опсега дубине потребне за екране који приказују 3Д садржај како би се приказале сцене компримоване у дубину, без уношења осећаја неприродности. Анализа процене квалитета доживљаја 3Д видео садржаја је део и истраживања у оквиру рада [60], а значаја део датог истраживања је предлог нове методе за процену квалитета и предлог нових метрика стереоскопског 3Д видео садржај. Значај се огледа и у томе да аутор истражује утицај брзине кадрова на искуство 3Д гледања са циљем да се идентификује одговарајућа брзина кадрова за 3Д видео снимање. Прегледни рад [61] представља концепт за процену квалитета доживљаја 3Д преноса видео записа (енгл. *3D streaming*), истицајући најновија достигнућа и тренутне изазове. Порука „да ће истраживања људског визуелног система заједно са математичким моделима, као и доступност 3Д видео база података за поређење резултата међу различитим истраживачким тимовима донети значајан помак у области процене 3Д квалитета доживљаја“ [61], представља изазов и подстрек да се на истраживању и настави. Тај изазов довео је до тога да се са 3Д садржаја пређе на 3Д видео игре и виртуалну реалност [77], а потом и на такозване имерсив медије (енгл. *immersive media*) [82]. Фокус истраживања [82] је пренос 3Д видео записа у складу са најновијим напретком у стандардизацији на пољу

процене квалитета доживљаја у апликацијама за компресију и разумевање визуелног ефекта асиметричног и симетричног кодирања за имерсив медије.

2.2 Преглед истраживања корелације психо-физиолошких мера и квалитета доживљаја

Након дефинисања и покушаја да се сертифициује, корелација психо-физиолошких параметара и квалитета доживљаја изазвала је револуцију истраживања. Осим психо-физиолошких параметара покушај да се покаже директна повезаност доживљаја квалитета и емоционалног стања отворила је потпуно нову област мултидисциплинарног истраживања.

У студији [25] аутори су истраживали на који начин имерсив медије утиче на осећај емоција у виртуелном окружењу. Испитујући два различита приказа, са и без опреме монтиране на глави корисника, као и две врсте садржаја, хорор и емпатија, аутори су доказали да је визуелна перцепција у директној вези са емоционалним стањем корисника, што је значајан податак и смерница употребљена у овој дисертацији. Затим, покушај да се разуме шта се дешава са можданим таласима кроз праћење електро-енцефалографских сигнала приликом визуелног доживљаја уметничког дела, као и на који начин промена био сигнала утиче на емоционално стање испитали су аутори [26]. Верује се да је у изради и дизајнирању динамичних слика, дуже време гледања узорака исте боје и облика даје бољу поузданост а овакав закључак донесен је на основ корелације информација на субјективној семантичкој скали и измереним подацима о можданим таласима корисника. Праћење ЕЕГ сигнала показало се од круцијалне важности за испитивање корелације квалитета доживљаја, емоционалног стања и био сигнала праћених сензорима. Осим поменутих многа друга истраживања (нпр. [17], [18], [19], [20], [22], [23], [24], [28], [29], [31], [32]) показују да је употреба психо-физиолошких сигнала као што су електро-кардиографски сигнали, електро-дермална активност и електро-енцефалографски сигнали кључни за процену емоционалног стања у различитим приликама. У раду [19] приказана је корелација између сигнала срчане фреквенције и електро-дермалне активности са искуством у компјутерским играма и емоционалним стањем играча.

Фокус аутора [29] је да представи научни допринос у смислу разумевања улоге психо-физиологије у истраживањима корисничког искуства. Студија нам даје везу између

искуства корисника, психо-физиологије и њених мерења, као и доказ да корисничко искуство може значајно утицати на дизајн производа.

Класификација емоционалних стања [28] и континуирано откривање задовољства корисника [30] током гледања филмских исечака или чак процена узбуђења доживљеног у имерсив виртуелној стварности [24] праћењем EEG сигнала популарне су теме истраживања.

2.3 Преглед модела за процену и предвиђање емоционалног стања и квалитета доживљаја

Многи аутори су покушали да уведу различите моделе за вештачко препознавање, класификацију и процену емоционалног стања. Методологије описане у [12][13][14][27][101][102][104][106][108][109] су биле одлична полазна тачка за избор вештачке неуронске мреже - вишеслојног перцептрона *MLP* као проценитеља или класификатора када је улаз у неуронску мрежу дат у облику психо-физиолошких сигнала.

У раду [13] разматрају се различити типови вештачких неуронских мрежа за класификацију емоционалног стања. Аутори су представили срчану фреквенцију и електро-дермалну активност као значајне улазне податке за дата мининг. Величина базе података у раду је добар показатељ како оптималан број улазних узорака у овој врсти студија даје добре резултате.

Рад [14] указује да је вишеслојни перцептрон као техника машинског учења добар избор када су улазни сигнали у системе и апликације у реалном времену, сигнали електро-енцефалографије. Као што је показано у [14], *EEG* сигнали као улазни подаци за вештачке неуронске мреже су одлични за употребу у различите сврхе истраживања, јер се класификација менталних задатака може радити са великом прецизношћу употребом више типова нелинеарних класификатора.

С друге стране, рад [16] описује врло сличан приступ као и истраживање које предлаже овај докторат користећи фази логику, те аргументовано описује све позитивне и негативне аспекте употребе вишеслојног перцептрона и на тај начин представља изазов даљем истраживању понашања вишеслојног перцептрона у ову сврху.

Приступ који је дат у [21] предлаже употребу мрежа за дубоко учење у сврху препознавања емоција, праћењем *EEG* активности и субјективног оцењивања

емоционалног стања користећи специфичну скалу за оцењивање названу *CAM* (енгл. *Self-Assessment Manikin*) коју овај докторат предлаже у исту сврху.

У [30] аутори описују понашање рекурентне неуронске мреже (енгл. *long-short-term-memory recurrent neural networks LSTM-RNN*) и континуирано условна случајна поља (енгл. *Continuous Conditional Random Fields CCRF*) које се користе за аутоматску и континуирану детекцију емоција. Приступ дат у [33] користи енгл. *K-means* технику за кластерисање у предвиђању дијагнозе срчаних обољења обрадом стварних и вештачких скупова података људских параметра.

У аутомобилској индустрији процена и предвиђање понашања возача и емоционалног стања играју важну улогу када је у питању сигурност. Предвиђање пажње возача, љутње [32], замора [17], [20] или препознавања емоционалних искустава [31] коришћењем *EEG* или *EDA* сигнала, такође, се извршава помоћу различитих техника машинског учења. Радови [22] и [23] описују употребу *SVM* (енгл. *Supporting Vector Machine*) за предвиђање таквог емоционалног стања. Други рад [34] предлаже начин процене емоција назван енгл. *Bio-emotion Estimate Method (BeEM)* који може да идентификује емоције применом можданих таласа и откуцаја срца процењених помоћу Раселовог кружног модела [3]. Још један доказ да је обрада сигнала вредан извор информација и да може бити моћно средство за процену је покушај аутора [18] да контролише возило коришћењем *EEG* сигнала.

3 Квалитет доживљаја

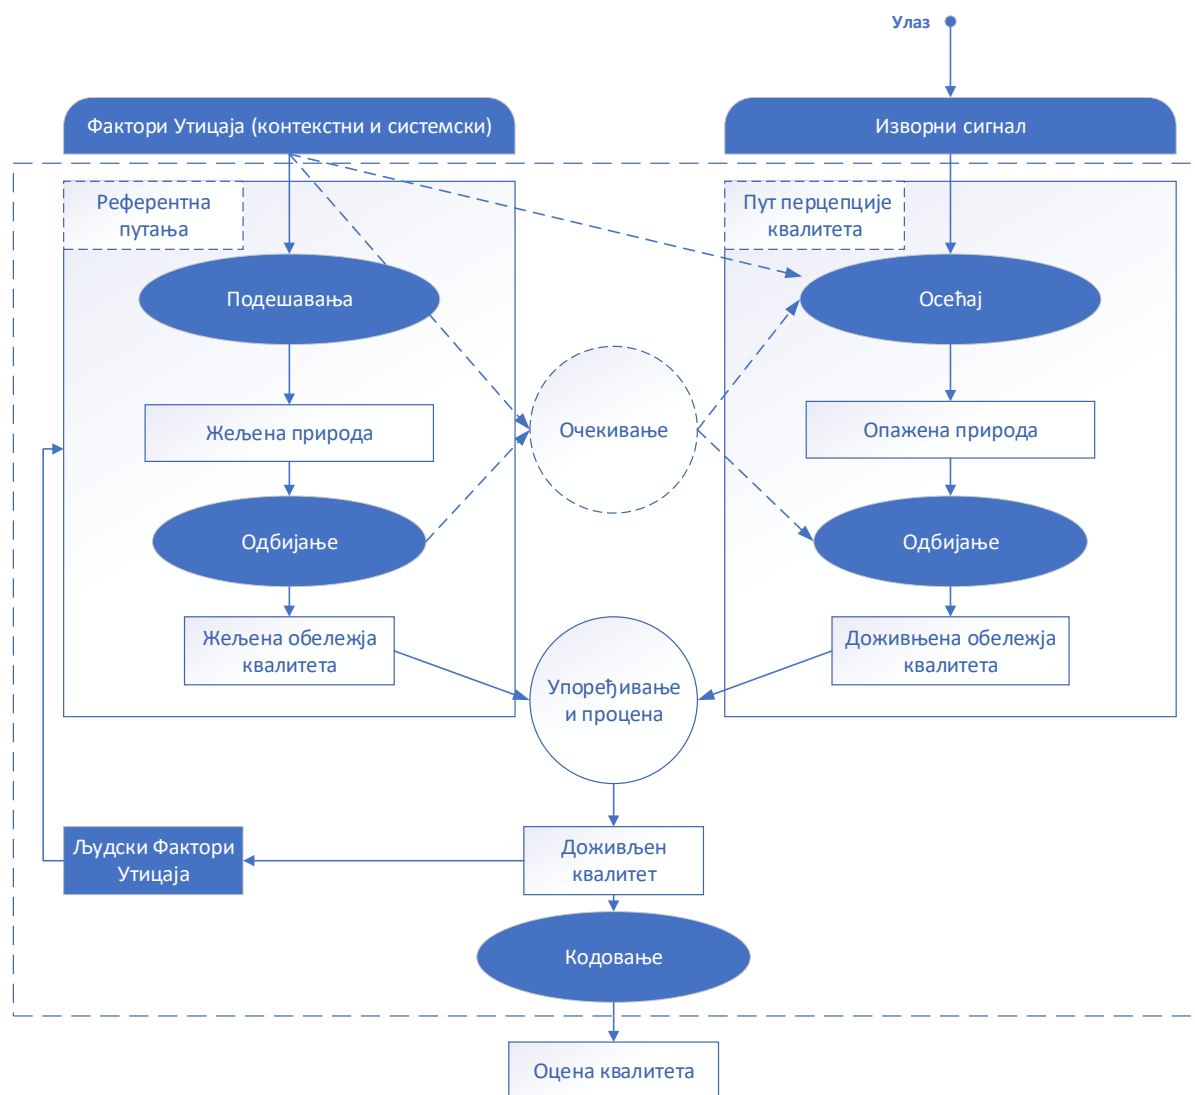
3.1 Дефиниција квалитета доживљаја

У сврху разумевања циља истраживања елаборираном у овом раду, неопходно је објаснити термине неколико основних термина: „догађај“, „доживљај“ и „квалитет“ у дефиницији квалитета доживљаја - *QoE*. Догађај је одређен простором у коме се појављује, временом када се догодио и карактером који му се може приписати. Доживљај је индивидуална перцепција и интерпретација једног или више догађаја [91]. Доживљај је резултат сусрета људског бића са техничким системом, услугом коју систем пружа или артефактом који је производ уметности и не мора нужно резултирати проценом његовог квалитета. Дефиниција доживљаја дата у [37] не обухвата све оно што је особа прошла у прошлости, већ је прошлост представљена као битан фактор утицаја на квалитет доживљаја. Фактори утицаја на квалитет доживљаја, као основ настајања, биће детаљније описани у наставку. Најзад, квалитет има набројано дефиниција детаљно побројаних у [65] али ће у овој дисертацији бити усвојена дефиниција [37] *„исход процеса индивидуалног поређења и просуђивања, који укључује перцепцију, контемплацију о концепцији и наративни резултат“*. Насупрот дефиницијама које квалитет виде као скуп инхерентних карактеристика, у контексту који је предмет овог истраживања, квалитет је процењена доброта и степена испуњености потреба.

Да би се коначно дефинисао квалитет доживљаја неопходно је разумети на који начин се формира квалитет што је детаљније приказано Сликом 1 [91]. Приликом формирања квалитета постоје два пута и то, пут перцепције и референтни пут. Референтни пут одражава временску, системску и контекстуалну природу процеса формирања квалитета и на њега утиче сећање на некадашње искуство, као што то показује стрелица на Слици 1 од доживљеног квалитета до референтне путање преко људских фактора утицаја. Пут перцепције квалитета узима физички догађај, покренут улазом као што је неки физички сигнал који долази до наших чулних органа – слух, вид итд. Под ограничењем референтне путање, физички догађаји се обрађују кроз осећај на ниском нивоу у опажену природу. Ова опажена природа тада пролазе кроз процес рефлексije, усмерен поново ка референтном путу, који когнитивном обрадом тумачи ове сензорне особине. Тада на основу излаза из обе путање настаје процес упоређивања и процене што води ка уочавању карактеристике

ПОГЛАВЉЕ 3 – Квалитет доживљаја

квалитета, тачније доживљеног квалитета. Описани процес се дешава унутар корисника те се релевантне информације о догађају могу се добити само на описном нивоу од корисника – оценом квалитета доживљаја.



Слика 1 – Процес формирања квалитета на основу [91]

На основу процеса формирања квалитета може се закључити да је квалитет доживљаја степен задовољства или узнемирености корисника апликације или услуге. То је резултат испуњења очекивања корисника у погледу корисности и/или уживања апликације или услуге у светлу личности корисника и тренутног стања.

Неопходно је напоменути да постоје и друге дефиниције као што је дефиниција дата препоруком *ITU-T* [93], која каже да је квалитет доживљаја општа прихватљивост апликације или услуге, како субјективно доживљава крајњи корисник. Ова дефиниција

повезује само садржај и квалитет доживљаја што није контекст овог елабората, већ да квалитет доживљаја не говори експлицитно о степену успеха који је креатор садржаја постигао да би пренео жељену поруку, него како би технички систем или техничка обрада могли позитивно или негативно утицати на успех преношења уметничке поруке.

Како би се разграничила дефиниција препоруке и дефиниције коју је дао *Qualinet* [37] коначна дефиниција термина који се користи у овом истраживању би била: „*Квалитет доживљаја је степен задовољства корисника услуге у контексту комуникационих услуга, а на њега утичу садржај, мрежа, уређај, апликација, очекивања и циљеви корисника и контекст употребе*“.

3.2 Фактори утицаја на квалитет доживљаја

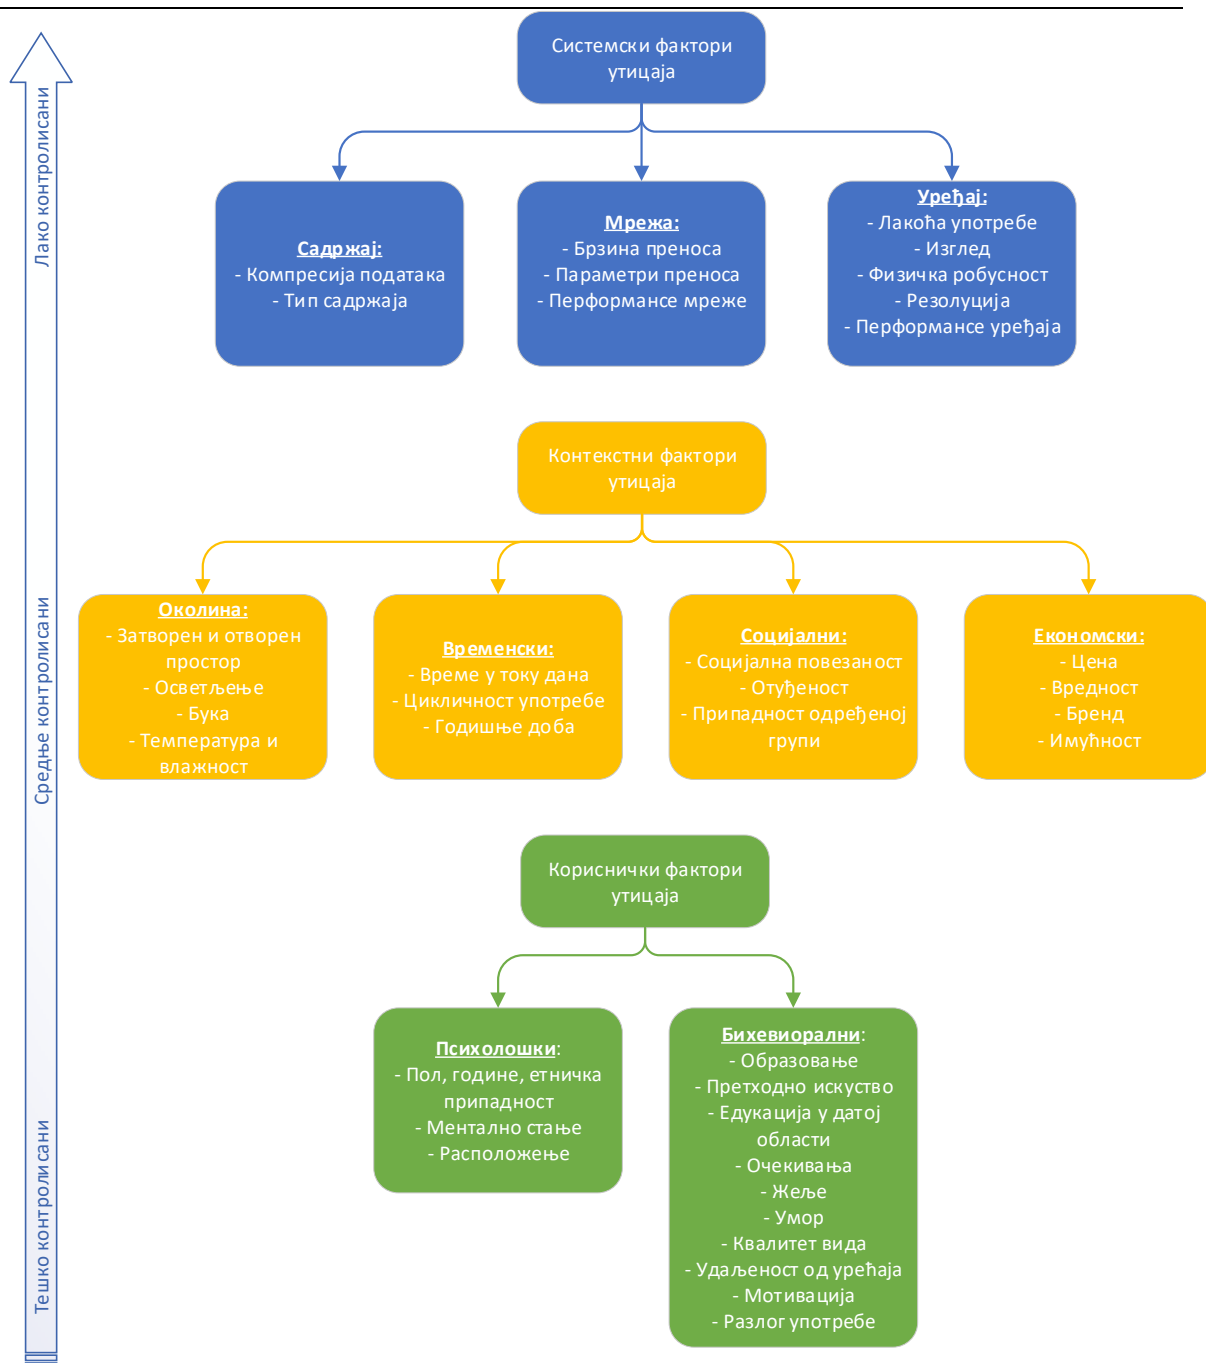
За разумевање квалитета доживљаја није довољно само дефинисати сам појам већ анализирати и факторе утицаја на квалитет доживљаја. Општа дефиниција фактора утицаја би била да су они било која карактеристика корисника, система, услуге, апликације или контекста чије стварно стање или подешавање може утицати на квалитет доживљаја корисника. Битно је напоменути да се фактори утицаја никако не смеју посматрати изоловано јер веома утичу једни на друге. Могу се поделити на:

- корисничке;
- контекстуалне и
- системске - техничке природе.

Детаљна подела и примери дати су на Слици 2. Са слике се може уочити да је системске најлакше контролисати док се кориснички готово и не могу контролисати и зависе од психо-физиолошког стања и дугорочног понашања корисника.

Кориснички фактори су они које се јављају на месту пријема код самог корисника, те је њихова природа готово најразноврснија и могу се поделити на оне који имају везе са психо-физиолошким особинама и основном поделом корисника (нпр. пол, године, емоционално стање) и оне које обрађују ниво претходног знања (нпр. образовање, искуство, ишчекивање, умор, едукација у датој области).

ПОГЛАВЉЕ 3 – Квалитет доживљаја

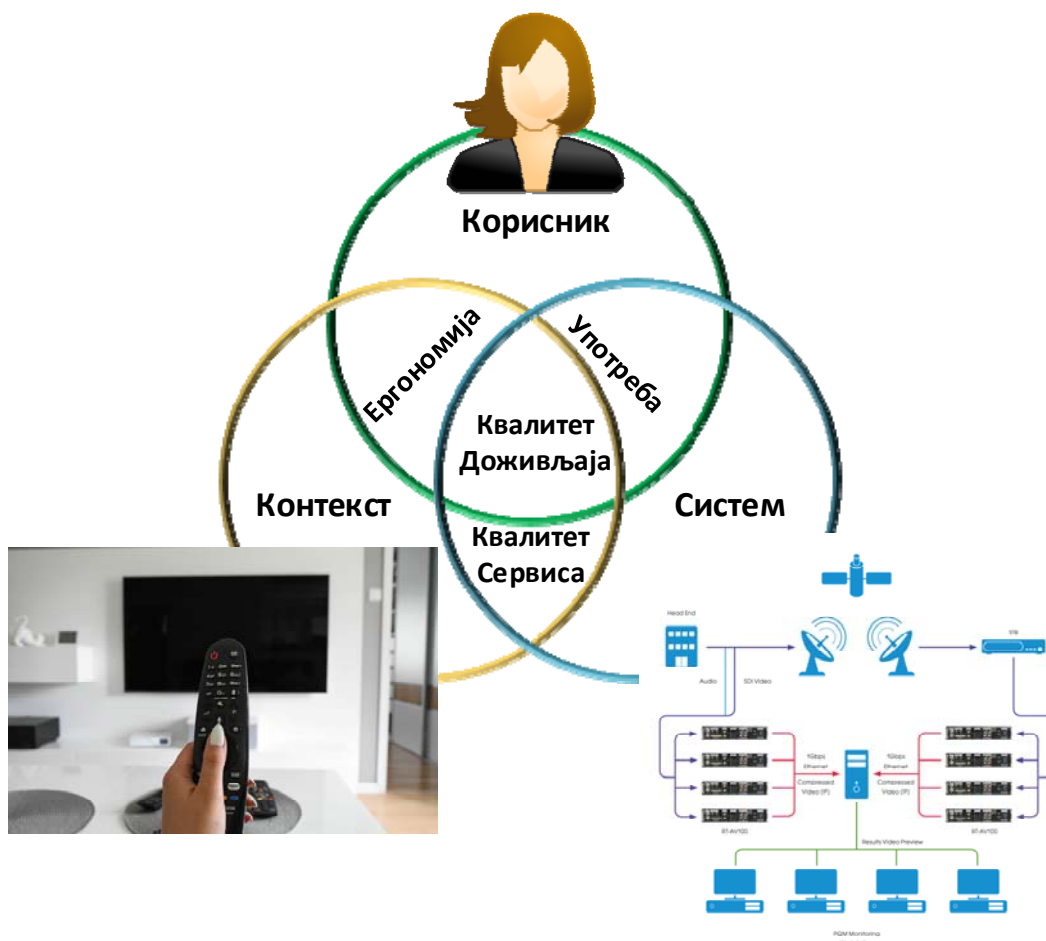


Слика 2 – Подела фактора утицаја

Најкомпликованији фактори утицаја су контекстуални фактори утицаја који се могу разматрати кроз контекст локације корисника, време употребе фреквенцију употребе садржаја, економски контекст, социјални, али и контекста због чега се користи неки садржај. Њихова компликованост се огледа у томе да се не могу лако предвидети, не постоји ни једна студија која их резимира детаљно и даје референтне вредности и врло често су

сакривени. Њихов утицај се може једино испитати кроз субјективни допринос самог корисника о чему ће детаљније бити речи у поглављу „Субјективне мере“.

Системски или технички фактори утицаја се могу лако контролисати и подешавати а њихова подела повезана је са садржајем који се пласира (нпр. тип садржаја, начин компресије и начин обраде итд.), мрежним параметрима (нпр. брзина преноса) и доступношћу мреже, као и уређајима, а посебно карактеристикама уређаја који интерагују у процесу и приказују неки садржај.



Слика 3 - Фактори утицаја на квалитет доживљаја

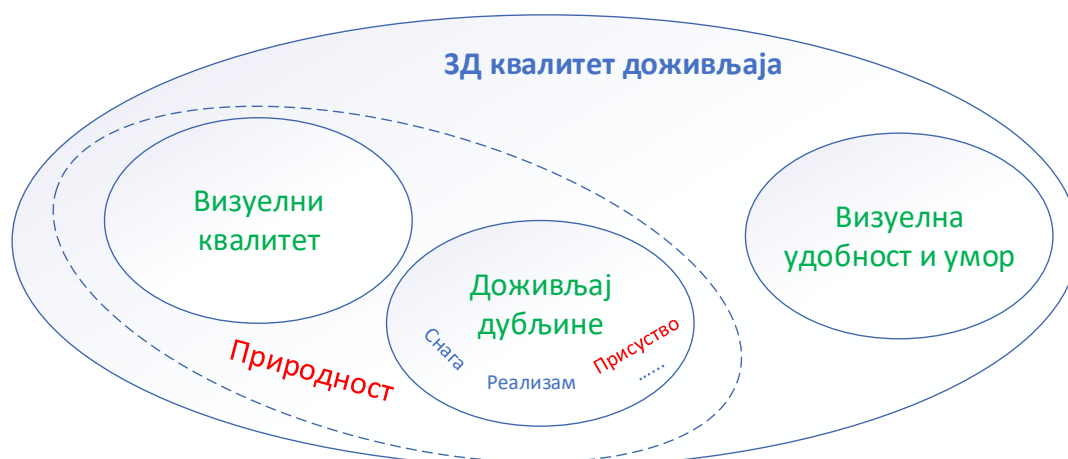
Као што је већ напоменуто фактори утицаја се не смеју посматрати независно већ се морају узети у обзир заједно (Слика 3), па тако ако пажљиво посматрамо корисника и контекст или корисника и систем можемо доћи до жељених параметра ергономије и употребе, респективно, што је од велике важности за делатности услужно забавног карактера као што су позориште и биоскоп. За сервисе који емитују неки садржај (нпр. телевизија, VoIP, интернет итд.) контекст и системски фактори утицаја играју важну улогу

јер се узимањем у разматрање оба може доћи до параметара квалитета сервиса. Међутим, основна тежња је да се добије пресек сва три фактора утицаја - квалитет доживљаја. На основу истраживања која обрађују на који начин се сви фактори утицаја могу пратити и подешавати у предефинисаним лабораторијским поставкама [55] може се доћи до значајних закључака који су референтна тачка за снимање база података. Ово је посебно значајно за доживљај квалитет виртуалне реалности, имерсив, 3Д и мулсмедија.

3.3 Квалитет доживљаја 3Д видео садржаја

Како би се разумела методологија и поставка докторске дисертације неопходно је увести и објаснити специфичности квалитет доживљаја 3Д видео садржаја. Наиме, осим основних принципа оцене 2Д квалитета доживљаја основи проблем који се појављује код оцене 3Д квалитета доживљаја де мулти-димензионалност. Тако осим претходно напоменутих фактора утицаја, 3Д квалитет доживљаја је дефинисан додатним обележјима што је приказано на Слици 4:

- Визуелна удобност;
- Визуелни квалитет;
- Квалитет дубине и
- Секундарни фактори: природност и присуство.



Слика 4 – Основна обележја 3Д квалитета доживљаја [69]

3.3.1 Кориснички фактори утицаја 3Д - Фактори перцепције корисника

Осим корисничких фактора утицаја уопште претходно описаних, фактори утицаја који се односе на перцепцију играју најбитнију улогу када је визуални стимулус људског визуелног система у питању, с обзиром да они обезбеђују разумевање онога што корисник види.

Визуелни квалитет 3Д видео садржаја се не разликује видно од онога што је већ познато за 2Д видео садржа, па су основна обележја: визуелна осетљивост, доживљај боје, просторно и временско маскирање и пажња. Визуелна осетљивост представља одговор људског визуелног система на светлост. Доживљај боје је субјективна мера како корисник види боју и због своје субјективности, али и чињенице да је људски визуелни систем мање осетљив у односу на доживљај светлости готово да није погодан за истраживања у области предвиђања квалитета доживљаја. Просторно и временско маскирање представља неспособност доживљаја стимулуса због другог доживљаја, па се недостатком просторног може доживети лоша текстура слике, а недостатком временског брзе сцене могу бити проблем. На крају, пажња је фактор који је од великог значаја за истраживања која се испитивањем региона и моделима пажње као улаз у енгл. *eye-tracking*.

Перцепцију дубине чине два различита фактора: количина дубине (колико се дубина перципира) и квалитет дубине (колико је веродостојно приказивање дубине). Људски визуелни систем, користећи знаке дубине, обрађује информације са различитих извора како би се постигао ефекат три димензије. Ти знаци се могу поделити на окуломоторне знаке – који се односе на позицију и тензију очних мишића (конвергенција и смештање фокусираног објекта) и визуелне знаке који зависе од једног ока и формирају две димензије (затварање, релативна величина и висина, позната величина, перспективна конвергенција, атмосферска конвергенција, текстура, сенка, монакуларна паралакса и релативна удаљеност) и визуелне знаке који зависе од оба ока и обезбеђују трећу димензију (бинакуларни диспаратет). Потребно је напоменути да је перцепција дубине различита код људи, па се квалитет доживљаја може различито оценити.

Визуелна угодност (нелагода) је најважнији фактор 3Д визуелизације због чињенице да највише утиче на прихватљивост неког 3Д садржаја. Неколицина радова бави се тематиком негативног ефекта 3Д видеа због тога што се може изазвати главобоља, мучнина, вртоглавица услед дупле слике, а од посебног значаја за ову докторску дисертацију је утицај на људске емоције [6], [54].

3.3.2 Ефекти услед системских фактора утицаја на 3Д

Како би се испитао ефекат утицаја системских и техничких фактора утицаја на доживљај квалитета 3Д, а посебно утицаја на емоционално стање неопходно је објаснити који и када се ефекти могу јавити. Једна од хипотеза дисертације је да ће уношење техничког оштећења допринети да се корисник бити несретнији ако је дисторзија већа, односно повећаће се визуелна непријатност. Системски фактори утицаја на 3Д садржај повезани су са настајањем (нпр. број камера који се користи, начин на који су постављене, тип садржаја, начин компресије и начин обраде итд.), преносом и мрежним параметрима (нпр. брзина преноса, кодовање итд.) и уређајима, а посебно карактеристикама уређаја који интерагују у процесу и приказују неки садржај. На Слици 5 приказан је једноставан ланац настајања и преноса 3Д видеа.



Слика 5 – Обрада и пренос 3Д видео садржаја

Свака етапа односи се на уређаје који интерагују у процесу и који користе одређене технике снимања, настајања, процесирања, кодовања-декодовања и начина приказа при чему се могу јавити визуелно неприхватљиви ефекти код корисника.

Тако услед настајања због употребе две или више камера повезаних на различите начине, те процесирања више 2Д видеа у један 3Д и стварања визуелне дубине, могу се јавити ефекти нетачне паралаксе (закривљеност камера је различита па се јавља ефекат у

угловима), ефекат картона, неслагање дубине, неслагање боје и ефекат лутке (неслагање величине људи са објектима у околини).

Ефекти настали услед кодовања 3Д видеа не разликују се у односу на оне који настају приликом кодовања 2Д видеа па се могу на исти начин појавити ефекат блокова, замућеност, шум итд. Међутим, ови ефекти могу појачати нелагоду код корисника и у потпуности елиминисати перцепцију 3Д видеа. Даље, ефекти настали услед трансмисије као што су замрзавање сцене услед губитка пакета, или макроблокирање услед немогућности да се на исправан начин декодује видео, кашњење, сецкање сцене итд. у потпуности ће утицати на корисничку перцепцију.

Са стране корисника у зависности од начина рендеровања 3Д видеа и типа уређаја који се користе у приказивању (нпр. два монитора, уређаји са хоризонталном паралаксом, потпуном паралаксом) могу се јавити енгл. *crosstalk*, ефекат који у потпуности уништава перцепцију 3Д видеа јер се појављују преклапајући објекти, затим ефекат оквира или нелагодност услед неадекватног осветљења у просторији и наочара за праћење 3Д видеа и многи други.

Сви побројани ефекти могу изазвати нелагодности код корисника, те потпуно елиминисање 3Д перцепције садржаја и на тај начин утицати на квалитет доживљаја, а посебно на емоционално стање корисника.

У поглављима „*Опис базе видео материјала*“ и „*Резултати*“ биће описана техничка оштећења, ефекти и анализа емоционалног стања услед њиховог постојања у 3Д видеу. Као пример биће дата анализа на најједноставнијој дисторзији, *Gaussian blur* узимајући у обзир неколико нивоа дисторзије и утицај на субјективну оцену.

4 Мерење квалитета доживљаја

4.1 Дводимензионални модел емоционалних стања

Мерење емотивног стања је свеобухватан и веома компликован процес јер захтева пре свега познавање психо-физиологије људи. У ту сврху потребно је разумети шта је емоција и на који начин се може класификовати на основу процеса настајања, а уколико се анализирају у сврху технолошког прогреса изазов се повећава.

Највећи значај у погледу дефинисања опште намене употребе, мерења и представљања емоција, који би требало да буду употребљиви у широком спектру технолошких контекста када је неопходно укључити аспекте емотивног стања корисника, добијен је кроз истраживање [94]. Емоција се може дефинисати кроз неколико компоненти: субјективна компонента, когнитивна компонента, физиолошка компонента, компонента понашања и изражајна компонента. Компоненте емоција се могу пресликати на процес настајања као што је то показано на Слици 6. Физиолошка и изражајна компонента помоћ су прикупљању објективних мера, а субјективна компонента субјективних мера, које ће детаљније бити описане у даљем тексту.



Слика 6 – Компоненте емоција и њихов утицај на процес стварања

Моделовање емоционалних стања у техничким системима је веома важно због побољшања комуникације рачунара и корисника и повећања ефикасности обраде система. Емоције су основни део људске комуникације и зато их треба узети у обзир, нпр. у системима за ћаскање (енгл. *chat*) или наглашеним говорним кутијама (енгл. *emphatic voice boxes*). Затим, емоција и интелигенција су чврсто повезане те се на тај начин може доћи до моделовања људских осећања у рачунарској обради и помоћи у изградњи ефикаснијих система, нпр. коришћење емоционалних модела за временски критично спровођење одлука итд.

У овој докторској дисертацији пажња је пре свега посвећења способности визуелне перцепције људи. Визуелна перцепција се може дефинисати као способност тумачења окружења обрадом информација садржаних у видљивом спектру, а представља психо-физиолошко стање које утиче на људско понашање. Модели процене емоција покушавају да концептуализују људско понашање дефинишући којој димензији припадају. Да би се измерило емоционално стање људи, мора се узети у обзир дводимензионални простор: позитивна до негативна скала емоција - задовољство и интензитет емоција - узбуђење [1]. Задовољство и узбуђење могу се мерити само укључивањем објективних и субјективних мера. Узбуђење се може мерити на различите начине путем психолошких сензора због корелације са аутономним нервним системом. Задовољство је у уској вези са узбуђењем и многи радови описују дводимензионални простор између емоција на основу промене узбуђења и задовољства. Пример дат у овом истраживању је приказан на Слици 7.



Слика 7 - Дводимензионални простор емоција [3]

Слика 6 показује да се емоција може категорисати само ако се узму у обзир и узбуђење и задовољство што показују и многа истраживања [2][3][4][6][7]. На пример, ако је задовољство позитивно, а људско тело детектује активно стање узбуђења, то значи да се понашање може класификовати као „срећно“. На основу емоционалног стања психо-физиолошки сигнали ће бити у неком распону фреквенције, а мождани таласи снимљени у неком одређеном региону мозга биће посвећен тој емоцији или активности. Дакле, емоционална стања, један од фактора људског утицаја на квалитет доживљаја, играју важну улогу у конзумирању видео садржаја те је њихова процена од изузетног значаја за дизајн видео садржаја.

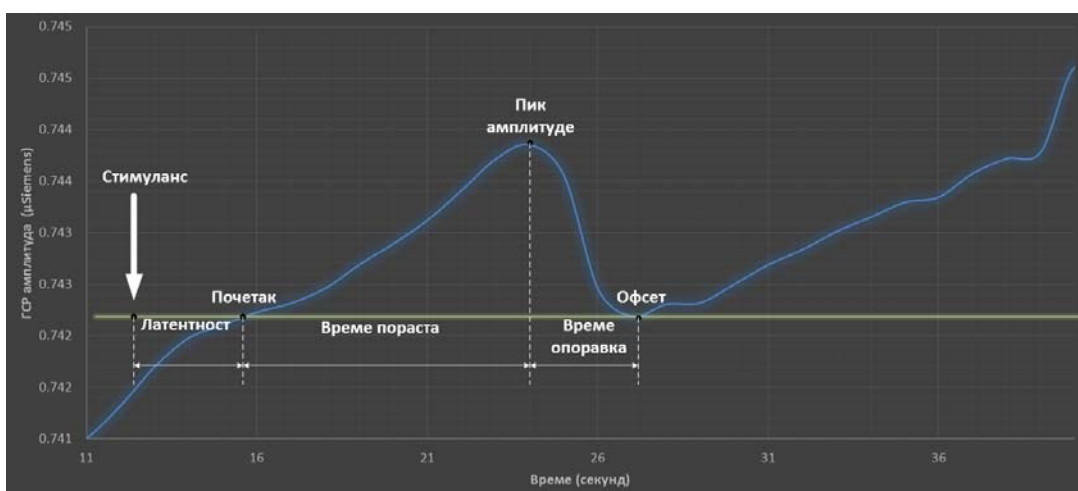
4.2 Објективне мере

У циљу лакшег разумевања методологије која се предлаже овим докторатом неопходно је објаснити објективне мере које ће се користити као улазни параметри у алгоритме машинског учења. Испробано је више алгоритама: више типова вештачких неуронских мрежа, линеарна регресија, енгл. *Decision Trees*, *SVM* током рада на истраживању али су резултати приказани само за одабране методологије. Сви објективни параметри који се користе као улазни подаци захтевали су посебну обраду и с тим у вези разумевање њихове природе, начина на који се мере, обележја која се могу из њих извући представљају веома битан аспект за почетак истраживања. У даљем тексту дат је краћи опис мера које су се користиле. Објективне мере које се разматрају у овом истраживању су психо-физиолошки сигнали који су детаљније описани у [5]: електро-кардиографски сигнали (енгл. *electrocardiograph ECG*), електро-дермална активност (енгл. *electro dermal activity EDA*) и електро-енцефалографски сигнали (енгл. *electroencephalograph EEG*).

Једна од најчешће експлоатисаних психо-физиолошких мера човековог емоционалног стања је електро-дермална активност *EDA* (енгл. *electro dermal activity EDA*). Електро-дермална активност [36] представља проводљивост коже која је у уској вези са индексом узбуђења, јер варијација углавном зависи од активности симпатичког нервног система [9][15]. Израчунава се као комбинована промена између електро-дермалне отпорности и потенцијала. Термини који се могу наћи у литератури, а ближе описују електор-дермалну активност, су галванска реакција коже (енгл. *galvanic skin response GSR*) и галвански потенцијал коже (енгл. *galvanic skin potential GSP*). *GSR*, мера проводљивости коже, резултат је знојних жлезда у људским рукама и стопалима које реагирају на психолошку


стимулацију уместо на температурне промене у људском телу [16]. Знојне жлезде делују као промењиви отпорници на површини и као последица тога, *GSR* се бележи као електрични отпор између две електроде на људским прстима исте руке када мала струја пролазила између електрода. *GSP* представља напон измерен између две електроде без икакве спољне струје. Овај напон варира са емоционалним стањем субјекта што значи да *GSR* линеарно корелише са узбуђењем [35] и одражава когнитивну активност [36]. Пример стварних промена *GSR* током конзумирања мирног видеа приказан је на Слици 8.

Будући да на такву активност утиче активност симпатичког нерва, који је, такође, у основи емоционалног узбуђења, *EDA* се сматра добрим представником димензије узбуђења емоција.



Слика 8 – Пример промене *GSR* код субјекта 7 током конзумирања мирног видеа „Lake”

EDA се обично мери стављањем две електроде на прсте или дланове (Слика 9б) и пропуштањем мале струје кроз њих, омогућавајући тако мерење варијација проводљивости током времена.




Слика 9 – Поставка електрода приликом мерења а) ECG б) EDA в) EEG

EDA сигнал је нестационарни таласни облик који укључује две компоненте: континуирани, полако променљиви ниво проводљивости коже (енгл. *Skin Conductance Level SCL*) и фазну компоненту која укључује тренутна повећања у односу на таласни облик, назван кондуктивност коже (енгл. *Skin Conductance Response SCR*). *SCR* је пропорционално повезан са бројем знојних жлезда које се активирају, што у суштини значи да што је појединац више емоционално узбуђен, количина *SCR* се повећава. Такође, се може закључити да је амплитуда *SCR* представник активности симпатичког нервног система. *SCR* се често назива „врхом“ активности (а самим тим и „врхом *GSR*“), јер се чини као брзо повећање вредности сигнала. Ако се *SCR* појави као одговор на стимулус (обично у року од пар секунди <5s), тада се назива *SCR* повезаним са догађајима који је значајан за ову докторску дисертацију, док се ако се појављује без уочљивог разлога, наводи као неспецифичан *SCR*. Многи радови усредсредили су се на информативну вредност различитих карактеристика које се могу издвојити из *EDA* (нпр. [8][12][13][49][50]) те представљају одличну полазну тачку за издвајање обележја из сирових података.

Електро-кардиографски сигнали људског тела, који мере срчане активности, као што су број откуцаја срца и варијабилност срчаног ритма (енгл. *heart rate variability HRV*), су сложенији за проучавање од електро-дермалне активности [4]. Што се тиче срчаних мера, срце инервишу две гране аутономног нервног система, наиме симпатички и парасимпатички систем. Мере срчане активности, срчана фреквенција и варијабилност срчане фреквенције могу пружити информације о менталном стању које су повезане или са симпатичком (нпр. емоционална узбуђеност) или парасимпатичком (нпр. фокус пажње, емоционална регулација) активацијом [44]. *ECG* се мери преко коже постављањем електрода на грудни кош (Слика 9а), руке и ноге. Електроде се користе за детекцију електричних промена које настају из електро-физиолошког обрасца срца, деполаризације и реполаризације (Слика 10) током сваког откуцаја срца. Генерално, добро је познато да су промене у електро-кардиографским сигнаlima повезане са веома узбудљивим искуством које је последица пажње и когнитивног напора. Многе научне студије описују овај однос, посебно однос срчане фреквенције (енгл. *Heart rate HR*) и варијабилности срчаног ритма према узбуђењу и стресу. У поглављу „Методe и фазе истраживања“ срчана фреквенција употребљена је као основна карактеристика испитивања електро-кардиографског сигнала. Када се догоди неко узбуђење, а у овом истраживању од посебног значаја - визуелно узбуђење, откуцаји срца постају повишени. Варијабилност срчаног ритма представља параметар од велике важности за истраживаче јер даје највише информација и то у форми

стандардне девијације срчаног циклуса тачније у међу интервалима узастопних „R“ таласа у откуцају срца.



Слика 10 - ECG сигнал

Чињеница да варијације понашања срца код различитих људи постоје, отежава начин припреме података за улаз у системе за предвиђање. На пример, здрави људи имају број откуцаја срца између 50-70 у минути, у стању без узбуђења. То значи да се ове вредности могу користити као референтне. С друге стране, људи са вишим крвним притиском имају већи број откуцаја у минути. Због ових варијација, промене у брзини откуцаја срца морају се прецизније разматрати, те боље разумевање промена у стању узбуђења може се постићи употребом стандардне девијације откуцаја срца, покретног просека срчане фреквенције или варијације срчане фреквенције. Из тог разлога у овом истраживању обратиће се пажња на те мере.

Коначно, можда активности у облику електро-енцефалографских сигнала су веома корисни подаци [24][25] у свим истраживањима везаним за емоционалне промене због спољног утицаја на људско тело - визуелно узбуђење, физичке промене итд.


Људски мозак се састоји од неколико режњева који се могу повезати са одређеним акцијама: темени (енгл. *parietal*), слепоочни (енгл. *temporal*), потиљачни (енгл. *occipital*) и чеони (енгл. *frontal*) режањ. На пример, добро је познато да је потиљачни режањ визуелни процесни центар који садржи већи део анатомског режња визуелног кортекса. Из тог разлога сигнали забележени у потиљачном региону имају велики утицај на истраживања која се односе на промену емоционалног стања, узбуђења, током посматрања неког видео садржаја. Функције теменог режња су обрада сензорних информација у вези са положајем делова тела и тумачење визуелних информација, као и процесирање говора. Због функције

ПОГЛАВЉЕ 4 – Мерење квалитета доживљаја

тумачења визуелних информација у теменом режњу овај део мозга се мора узети у обзир у овом истраживању. Слепоочни режањ повезан је са асоцијацијом емоција, и то не само тренутним, већ и са онима који су дубоко у нашем уму. Једна од функција слепоочног режња је пажња, што значи да се ово подручје мозга мора узети, такође, у обзир. Са друге стране, у разматрање треба узети и категоризацију активности у односу на осцилације неурона у мозгу и њихових фреквенција. Сигнали између неурона у мозгу стварају огромну количину електричне активности која се може открити *EEG* мерењем нивоа електричне енергије у неком од режњева. Ум регулише своје активности помоћу електричних таласа који се региструју у мозгу. Мали електрохемијски импулси различитих фреквенција нам могу рећи какве су тренутне акције људског ума и тела. Постоји неколико можданих таласа сумираних у Табели 1: *алфа*, *бета*, *гама*, *тета* и *делта* таласи.

| Мождани таласи | Фреквенција (Hz) | Карактеристике | Режањ |
|-----------------------|------------------|----------------------------------------------------------|-----------------------------------------------------------------|
| <i>Alpha</i> α | 8 - 12.99 | Опуштеност, мир, релаксација | потиљачни (<i>occipital</i>), темени (<i>parietal</i>) |
| <i>Beta</i> β | 13 - 30 | Активно стање, заузетост, нека радња, размишљање | чеони (<i>frontal</i>), темени, слепоочни (<i>temporal</i>) |
| <i>Gamma</i> γ | 30 - 100 + | Узбуђење, формирање идеја, говор, обрада меморије, учење | чеони, темени |
| <i>Theta</i> θ | 4 - 7.99 | Поспаност, малаксалост, дубока релаксација | чеони, слепоочни |
| <i>Delta</i> δ | 0.2 - 3.99 | Дубоки сан | |

ТАБЕЛА 1 - МОЖДАНИ ТАЛАСИ



Слика 11 – Делови мозга – светло плаво чеони режањ, наранџасто темени режањ, зелено слепоочни режањ, розе потиљачни режањ

Алфа таласи имају фреквенцију од 8 до 12,99 Hz и њихова детекција је могућа у стању физичке и менталне релаксације као и свести о томе шта се дешава око нас. *Бета* таласи су у опсегу од 13 до 30 Hz и емитују се када је људско тело свесно узбуђено или се осећа узнемирено, напето или само ради било шта. *Гама* таласи се емитују на фреквенцији изнад

30 Hz и односе се на формирање идеја, обраду говора и меморије, као и на различите типове учења. *Тета* таласи су повезани са екстремном релаксацијом и њихов распон варира између 4 и 7,99 Hz. Коначно, делта таласи су у опсегу између 0.2 и 3.99 Hz и повезани су са веома дубоким сном и нису корисни за ово истраживање. Ако се мождани таласи мере у одређеном режњу, могу се открити корисни подаци о стању човека и његовим емоцијама. Мерење описаних таласа електродама постављеним на кожи главе (Слика 9в), у одређеним режњевима мозга, добиће се значајна количина података те се даље може искористити као улаз у механизме машинског учења представљених у овом раду.

4.3 Субјективне мере

Субјективна процена квалитета слике и видеа важан је аспект целокупне оцене неког садржаја због бројних ограничења која могу бити присутна код објективне процене. Тако се на пример субјективна процена може користити у дигиталној телевизији за процену утицаја кодека слике на квалитет слике, али и у рачунарским системима за процену укупног аудио-визуелног квалитета мултимедијалних апликација као што су апликације за видео конференције и слично. Она се пре свега заснива на резултатима које корисници додељују приказаним сликама или секвенцама. То је најпоузданији и најтачнији начин оцене квалитета јер у њој учествују крајњи корисници.


Како би се субјективна процена квалитета спровела неопходно је обратити пажњу на околину у којој се спроводи оцењивање, узорак посматрача који учествују у оцени, опрему која се користи приликом оцене, припремне тестове пре процене, дужину приказивања стимулуса, паузе и трајање времена оцене, као и на избор методологије. Субјективно оцењивање се може спровести у лабораторијским условима или у специјално намештеним собама које имитирају стварно окружење животног простора корисника. У зависности од окружења подешавају се осветљење собе, осветљеност околине у односу на екран, хроматичност позадине, однос осветљености неактивног екрана, однос осветљености позадине итд. Такође, је неопходно одредити параметре опреме и раздаљине посматрања па се при томе бира тип екрана, раздаљина од екрана, дијагонала екрана, резолуција и слично. Узорак посматрача зависи од садржаја који се приказује и врсте теста. Број посматрача варира у односу на специфичност оцењивања од најмање 15 до довољних 5 са експертским знањима одређених дијагноза дисторзија [95]. Опсежнија испитивања често захтевају више нестручних проценитеља подељених у неколико група. Сврха теста мора

бити описана и објашњена свим учесницима, а посебно уколико постоје могући негативни ефекти. Ово је посебно важно у случају процене квалитета 3Д материјала где излагање стимулусима може бити непријатно. Информације морају бити доступне у штампаној или дигиталној форми приручника и доступни пре тестирања.

Учесници морају проћи и припремне тестове нормалне оштрине вида (нпр. *Snellen charts*), затим тест на далтонизам (нпр. *Ishihara plates*) или у случају стереоскопског садржаја тестове за 3Д перцепцију дубине (нпр. *Randot, Titmus Stereo Fly, Frisby plates*).

Приликом тестирања учесницима се приказују одређени низ садржаја, а то могу бити оригиналне, неоштећене и обрађене слике. Учесници могу бити и обавештени о врсти тренутно приказаног сигнала, било да је обрађен или оригиналан, па се на основу тога може разликовати три врсте субјективних метода процене: са пуном референцом - референтни сигнал је присутан у скупу података и учесник зна који је сигнал референтни, са скривеном референцом - референтни сигнал је присутан у скупу података, али учесник нема информацију који је сигнал и без референце - референтни сигнал није присутан у скупу података.

Бодовање се одређује на скали која се назива просечна оцена мишљења (енгл. *Mean Opinion Score MOS*) која одговара оцени квалитета учесника. Када се користи референтни сигнал, постоје верзије као што су разлика просечна оцена мишљења (енгл. *Difference Mean Opinion Score DMOS*) или упоредна просечна оцена мишљења (енгл. *Comparison Mean Opinion Score CMOS*). Приликом рада на докторској дисертацији, а описано у одељку „Радови који претходе докторској дисертацији“ акценат [101][102][103][104] је био на употреби *MOS*, а у радовима [108][110] на *DMOS* скали.



а)



б)


Слика 12 – а) Континуална скала и б) компаративна скала

Скала просечне оцене мишљења може имати неколико варијанти у односу на број оцена који се користи, па тако могу бити са пет, седам, девет и једанаест оцена, у виду континуалне или компаративне скале.

У области процене квалитета 3Д садржаја може се наћи више препорука методологија за оцењивање као што су: *Single Stimulus SS*, *Single Stimulus Continuous Quality Evaluation SSCQE*, *Stimulus Comparison SC*, и *Simultaneous Double Stimulus for Continuous Evaluation*, али још увек не постоји тачна стандардизација. Корак ка стандардизацији дали су аутори [96] који укључују још неке познате методологије за оцену 2Д садржаја које се раније нису користиле за 3Д садржај: *Absolute Category Rating with Hidden Reference ACR-HR* и *Double Stimulus Impairment Scale DSIS*.

Међутим, све набројане методологије настале су како би се оценио само технички квалитет садржаја и употребљене су у истраживањима која су била део процеса докторске дисертације, али нису погодне за истраживања емоционалног стања корисника.

Да би се разумело емоционално стање човека приликом гледања специфичног 3Д видео садржаја, потребно је употребити неку од процедура за психо-физиолошку самопроцену. За ово истраживање одабрана је SAM (енгл. *Self-Assessment Manikin SAM*) процедура за самопроцену узбуђења и задовољства [6]. SAM процедура је техника процене у облику сликовног садржаја, искључујући вербални садржај који мери узбуђење и задовољство. На Слици 13 [6][7] приказана је скала која се користи за самопроцену.



Слика 13 - *Self-Assessment Manikin* скала са 9 нивоа оцена за узбуђење и задовољство

Поред узбуђења и задовољства, SAM може да мери доминацију која није релевантна за ово истраживање. Оцењивање узбуђења и задовољства преко 9 тачака SAM скале преноси људску афективну реакцију на визуелни стимуланс, у овом случају на различит 3Д видео садржај.

Како би се субјективне мере прикупиле потребно је спровести SAM процедуру по препоруци на следећи начин. Пре гледања видео секвенце и самооцењивања емоционалног стања, испитаници се морају тестирати на оштрину вида и тестове за доминацију ока, како би гарантовали да је њихов вид добар на исти начин како је то објашњено приликом субјективног оцењивања техничког квалитета. Након што испитаници заврше тестове, добијају упутства како да изврше процедуру самопроцене уз помоћ SAM [6], а за то време електроде су постављене за мерење објективних мера. Експериментални део истраживања представљен је детаљно кроз [5], а представља само почетну тачку овог истраживања.

5 База података

5.1 Опис базе видео материјала

Током овог истраживања у сарадњи са *Политехничким факултетом Универзитета у Нанту (Polytech Nantes, a French 'Grande École')* снимљена је база видео материјала. Базе је представљена и анализирана у [5] и употребљена у овом раду као референца за даља истраживања.

Гледање је изведено по ИТУ препорукама тачније у складу са ИТУ-Т ВТ.500 [98]. Садржај је приказан на *Acer GD245HQ* монитору повезаном са *NVidia 3D Vision System*. За сваку видео секвенцу предложене су две независне варијабле које се називају садржај и визуелна нелагодност дате у три вредности. Ове две независне варијабле неопходне су како би се проверила два задата циља: утицај садржаја на емоционално стање и утицај техничког квалитета на емоционално стање. Три вредности независне варијабле садржаја, обухватају три типа који се разликују на основу нивоа кретања, брзине сечења, природе слике и природне напетости. То значи да је тип један врло миран видео (кодирани са 0) који садржи снимке објеката и пејзажа преузетих из јавно доступне базе [99], тип два је нормалан видео (кодирани са 1) са нормалном количином измена у сцени преузетих из синтетизованог краткометражног филма [100] и тип 3 је видео са напетом сценом преузетих из комерцијалних хорор или екстремно акционих филмова (кодирани са 2). Слика 14 приказује пример сцена за сваки тип.



Слика 14 – Приказ сцена видео Типа 1, Типа 2 и Типа 3 респективно (с лева на десно) [5] [99][100]

Визуелна нелагодност има и три вредности у смислу различитих нивоа дисторзије (енгл. *Gaussian blur*), такође, кодирани као 0 (мала дисторзија), 1 (умерена дисторзија) и 2 (висока дисторзија). Слика 15 приказује пример нивоа дисторзије за видео Типа 2. Ове две

независне варијабле и њихови нивои дају девет видео секвенци са трајањем од 2 минута за сваког учесника које садрже све комбинације нивоа за обе независне варијабле.



Слика 15 – Пример сцена са визуалном нелагодности [5][100]

У Табели 2 може се видети пример за 3 учесника. Редослед презентације секвенци за остале учеснике обухватао је различите пермутације између узбуђења секвенце (ниско, умерено, високо) и визуелне нелагодности (ниско, умерено, високо). Број испитаника који су гледали видео секвенце је укупно 18. За *EEG* модел укупан број узорака је био 162 због 9 секвенци и 18 испитаника. Због неких проблема евидентирања карактеристика срчаног ритма и електор-дермалне активности за 6 испитаника, недостају подаци, а број узорака за срчаног ритма и електор-дермалне активности је 108.

С друге стране, укључене су зависне варијабле, наведене у претходним поглављима као субјективне мере. Субјективни резултати су дати за сваку видео секвенцу, а прикупљање за сваког испитаника се бележи као мера емоционалног стања које желимо проценити.

5.2 Поставка експерименталног снимања

Приликом прикупљања оцена и објективних мера испитаници су гледали 9 видео секвенци, представљених у случајном редоследу који је био различит за сваког учесника. Између секвенци, приказан је црни екран у трајању од 30 секунди, и испитаници су изабрали једну од 9 слика, како за скалу задовољства тако и за скалу узбуђења употребом САМ процедуре (Слика 13) за претходно приказан видео низ. Трајање сваке видео секвенце било је 120 секунди. Психо-физиолошке, објективне мере су прикупљене целом дужином трајања видео секвенце. Резултати експеримента само-оцењивања у виду САМ резултата пренесени су на нумеричку нотацију резултата тачније оцене од 1 до 9 и употребљене су као циљани вектор за процену емоционалног стања у моделима машинског учења који су представљени у наставку.

Иако релативно мали, број узорака сматра се одговарајућим, узимајући у обзир разноликост сигнала укључених у модел, али и баланс са напором потребним да се овакви подаци прикупе с обзиром на чињеницу да је било потребно да сви учесници појединачно погледају целокупни видео садржај.

| Видео секвенца дужине 120 секунди | Емотивни надражај | Визуелна Нелагодност Субјекат 1 | Визуелна Нелагодност Субјекат 2 | Визуелна Нелагодност Субјекат N |
|-----------------------------------|-------------------|---------------------------------|---------------------------------|---------------------------------|
| Секвенца 1 | Низак | Ниска | Средња | Средња |
| Секвенца 2 | Низак | Средња | Висока | Ниска |
| Секвенца 3 | Низак | Висока | Ниска | Висока |
| Секвенца 4 | Средњи | Ниска | Средња | Средња |
| Секвенца 5 | Средњи | Средња | Висока | Ниска |
| Секвенца 6 | Средњи | Висока | Ниска | Висока |
| Секвенца 7 | Висок | Ниска | Средња | Средња |
| Секвенца 8 | Висок | Средња | Висока | Ниска |
| Секвенца 9 | Висок | Висока | Ниска | Висока |

ТАБЕЛА 2 – ПРИМЕР ВАРИЈАЦИЈЕ ВИЗУЕЛНЕ НЕЛАГОДНОСТИ ЗА РАЗЛИЧИТЕ УЧЕСНИКЕ

Дизајн је обухватио само једно гледање секвенци од стране сваког учесника, с обзиром да је, када се ради са емоционалним подстицајима, новина фактор који се не сме одбацити. Наиме ако би учесници експеримента гледали исте секвенце више пута, друго (и наредно) гледање истих секвенци вероватно би имало ефекат понављања, стога изазване емоције не

би биле потпуно исте као приликом првог гледања. На пример, у узбудљивијим секвенцама, након првог гледања, учесник зна шта ће се следеће догодити, па би у другом гледању вероватно емоције биле умањене или потпуно промењене (нпр. од узбуђења до досаде).

Субјективни резултати су прикупљени за сваку видео секвенцу, а затим употребљени као мера за процену емоционалног стања тачније квалитета доживљаја. Пример оцена за 12 учесника може се видети у Табелама 3, 4 и 5. Приликом прикупљања оцена у оквиру САМ процедуре спроведена је и серија анализе оцене задовољства узбуђења учесника употребом статистичке методе *ANOVA*.

| Миран видео | Видео 1 | | | Видео 2 | | | Видео 3 | | |
|-----------------|----------|-------------|---------------|----------|-------------|---------------|----------|-------------|---------------|
| | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења |
| 1 | 1 | 2 | 0 | 2 | 3 | 1 | 1 | 6 | 2 |
| 2 | 1 | 5 | 1 | 5 | 5 | 2 | 2 | 5 | 0 |
| 3 | 1 | 7 | 2 | 1 | 6 | 0 | 1 | 9 | 1 |
| 4 | 1 | 5 | 0 | 1 | 1 | 2 | 1 | 9 | 1 |
| 5 | 2 | 5 | 2 | 2 | 3 | 1 | 2 | 2 | 0 |
| 6 | 6 | 2 | 1 | 1 | 6 | 0 | 1 | 8 | 2 |
| 7 | 1 | 1 | 0 | 2 | 1 | 1 | 1 | 2 | 2 |
| 8 | 2 | 6 | 1 | 1 | 4 | 2 | 1 | 5 | 0 |
| 9 | 1 | 8 | 2 | 1 | 9 | 0 | 1 | 9 | 1 |
| 10 | 1 | 4 | 0 | 2 | 5 | 2 | 1 | 6 | 1 |
| 11 | 2 | 6 | 2 | 2 | 7 | 1 | 1 | 8 | 0 |
| 12 | 1 | 7 | 1 | 2 | 3 | 0 | 1 | 2 | 2 |
| Средња вредност | 1.67 | 4.83 | | 1.83 | 4.42 | | 1.17 | 5.92 | |

ТАБЕЛА 3 - ОЦЕНЕ СУБЈЕКТА ЗА ВИДЕО МИРНОГ САДРЖАЈА

Анализа оцена задовољства показала је да нема значајног великог ефекта ни садржаја ни визуелне нелагоде на оцену задовољства. Међутим, утврђена је значајна разлика у оценама узбуђења које се односе на тип садржаја, али не и на визуелну нелагоду и интеракцију ових фактора.

Упарена поређења показала су да су просечне оцене узбуђења различите за све три врсте садржаја што се може видети из Табела 3, 4 и 5. Како је и било очекивано, а на овај начин и потврђено, садржај видеа Типа 1 који су представљали видео садржај мирног типа били су далеко мање узбудљиви од садржаја видеа Типа 2, окарактерисаног као садржај умерене активности. На крају видео садржаји Типа 2 били су мање узбудљиви од Типа 3 који се представљен као филмски жанр хорора.

ПОГЛАВЉЕ 5 – База података

Потврда да је већина субјеката на сличан начин оценила скале узбуђења и задовољства приликом САМ процедуре доказ је да је визуелна перцепција 3Д видео садржаја и емоционална само-оцене у нераскидивој повезаности, те се узорци само-оцене могу користити као референтна оцена неког садржаја.

| Умерено-активан видео | Видео 4 | | | Видео 5 | | | Видео 6 | | |
|------------------------|-------------|-------------|---------------|-------------|-------------|---------------|-------------|-------------|---------------|
| | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења |
| 1 | 4 | 5 | 0 | 4 | 4 | 1 | 5 | 4 | 1 |
| 2 | 5 | 6 | 1 | 5 | 5 | 2 | 1 | 2 | 2 |
| 3 | 1 | 9 | 2 | 1 | 7 | 0 | 4 | 3 | 0 |
| 4 | 1 | 9 | 0 | 1 | 9 | 2 | 1 | 4 | 1 |
| 5 | 7 | 8 | 2 | 8 | 8 | 1 | 7 | 8 | 0 |
| 6 | 7 | 5 | 1 | 7 | 6 | 0 | 8 | 2 | 2 |
| 7 | 6 | 6 | 0 | 6 | 5 | 1 | 7 | 6 | 2 |
| 8 | 5 | 3 | 1 | 2 | 3 | 2 | 5 | 3 | 0 |
| 9 | 3 | 6 | 2 | 2 | 5 | 0 | 4 | 5 | 1 |
| 10 | 4 | 4 | 0 | 4 | 4 | 2 | 4 | 2 | 1 |
| 11 | 2 | 8 | 2 | 1 | 8 | 1 | 2 | 8 | 0 |
| 12 | 2 | 5 | 1 | 3 | 6 | 0 | 3 | 5 | 2 |
| Средња вредност | 3.92 | 6.17 | | 3.67 | 5.83 | | 4.25 | 4.33 | |

ТАБЕЛА 4 - ОЦЕНЕ СУБЈЕКТА ЗА ВИДЕО УМЕРЕНО АКТИВНОГ САДРЖАЈА

| Хорор | Видео 7 | | | Видео 8 | | | Видео 9 | | |
|------------------------|-------------|-------------|---------------|-------------|-------------|---------------|-------------|-------------|---------------|
| | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења | Узбуђење | Задовољство | Ниво оштећења |
| 1 | 6 | 7 | 0 | 7 | 7 | 1 | 6 | 8 | 2 |
| 2 | 3 | 5 | 1 | 6 | 6 | 2 | 7 | 6 | 0 |
| 3 | 4 | 9 | 2 | 7 | 8 | 0 | 8 | 9 | 1 |
| 4 | 1 | 9 | 0 | 3 | 9 | 2 | 4 | 9 | 1 |
| 5 | 6 | 7 | 2 | 4 | 8 | 1 | 8 | 9 | 0 |
| 6 | 9 | 1 | 1 | 9 | 2 | 0 | 5 | 7 | 2 |
| 7 | 7 | 7 | 1 | 8 | 6 | 2 | 8 | 7 | 0 |
| 8 | 3 | 4 | 2 | 6 | 7 | 0 | 3 | 6 | 1 |
| 9 | 4 | 5 | 0 | 5 | 5 | 1 | 5 | 7 | 2 |
| 10 | 7 | 1 | 2 | 7 | 1 | 1 | 5 | 3 | 0 |
| 11 | 3 | 7 | 1 | 4 | 7 | 0 | 2 | 8 | 2 |
| 12 | 3 | 4 | 0 | 5 | 4 | 2 | 6 | 4 | 1 |
| Средња вредност | 4.67 | 5.50 | | 5.92 | 5.83 | | 5.58 | 6.92 | |

ТАБЕЛА 5 - ОЦЕНЕ СУБЈЕКТА ЗА ВИДЕО ХОРОР САДРЖАЈА

На основу *ANOVA* анализе добијене су корисне информације за сваки тип садржаја, те су на тај начин извучени закључци. Садржај Типа 3 повећао је ниво *EDA* у поређењу са садржајем Типа 1, који је третиран као референтни, док није било значајних ефеката садржаја Типа 2. Значајно запажање за видео Типа 1 односи се на ефекат визуелне нелагодности током времена у односу на смањивање *EDA*, јер добијени резултат сугерише да је, како време пролази, овај ефекат умерен. Међутим, у случају садржаја Типа 2 и 3, ти ефекти су обрнути: интеракције између визуелне нелагодности и Типа 2 и између визуелне нелагодности и Типа 3 сугеришу да се визуелна нелагодност повећава *EDA* за те врсте садржаја, док трострука интеракција између ових садржаја, визуелне нелагодности и времена сугерише да се овај ефекат временом смањује. Дакле, у случају садржаја Типа 1 визуелна нелагодност смањује узбуђење, али то смањење се временом готово нестаје, док код садржаја Типа 2 и 3 визуелна нелагодност повећава узбуђење, али се ово повећање смањује током времена.

Један од закључака, уколико се посматрају снимљене вредности објективних мера је и да је значајан пораст *EDA* и срчаног ритма (енгл. *Heart Rate HR*) у садржају Типа 3 доказ да је он био узбудљивији у поређењу са Типовима 1 и 2, што се одражава на оцене САМ. Такође, је утврђен пораст *HR* у вези са интеракцијом између визуелне нелагодности и садржаја Типа 2, али не и са интеракцијом између садржаја визуелне нелагодности и Типа 3 због чињенице да је садржај Типа 3 већ показао већи *HR* па је „ефекат плафона“ спречио да се *HR* додатно повећа у случају типа 3 у поређењу са садржајем типа 2. Стога све посматране интеракције између типа и техничких оштећења видео садржаја сугеришу да визуелна нелагодност повећава узбуђење и смањује задовољство. Детаљна анализа дата је у „Дискусија и резултати“ у односу на метод предвиђања који ће бити изложен у „Метод и фазе истраживања“.

6 Преглед употребљених алгоритама

6.1 Вештачке неуронске мреже


Вештачке неуронске мреже су сложени алгоритми и неуронске структуре које означавају поједностављену представу веома сложених неуро-физиолошких и психолошких процеса. Основна идеја ових алгоритама је опонашање начина учења који се дешава природно у људском мозгу. Вештачке неуронске мреже су далеко једноставније узимајући у обзир природне неуронске мреже које приближно имају 100 милијарди неурона и чак хиљаду пута више синапси.

Модел вештачких неуронских мрежа састоји се од скупа синапси који повезују неуроне и имају придружен тежински коефицијент w_{kj} за k -ти неурон на j -тој синапси, затим суматора улаза претходно помноженим тежинским фактором и активационе функције за ограничавање вредности излаза. Математичка представа неурона дата је двема једначинама (6.1.1) и (6.1.2):

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (6.1.1)$$


$$y_k = f(u_k - \theta_k) \quad (6.1.2)$$

при чему су x_1, x_2, \dots, x_n улазни сигнали, $w_{k1}, w_{k2}, \dots, w_{kn}$ тежински коефицијенти синапси k -тог неурона, u_k линеарна комбинација улаза, θ_k праг k -тог неурона, $f(\cdot)$ нелинеарна преносна функција неурона - активациона функција и y_k излаз k -тог неурона.



Слика 16 – Нелинеарни модел неурона

Од највеће важности за понашање излаза неурона је избор активационе функције $f(\cdot)$. Обично се за активациону функцију користе праг функција (6.1.3), изломљена линеарна функција (6.1.4), сигмоидна функција у облику логистичке (6.1.5), или тангенс хиперболичне (6.1.6), и *Gausova* функција (6.1.7), приказане на Слици 17.



Слика 17 – Активационе функције а) праг функција, б) изломљена линеарна функција, в) логистичка функција г) тангенс хиперболична функција д) Гаусова (радијално базна) функција

$$y_k = f(u_k) = \begin{cases} 1, & u_k \geq 0 \\ 0, & u_k < 0 \end{cases} \quad (6.1.3)$$

$$y_k = f(u_k) = \begin{cases} 1, & u_k \geq \frac{1}{2} \\ u_k + \frac{1}{2}, & \frac{1}{2} > u_k > -\frac{1}{2} \\ 0, & u_k \leq -\frac{1}{2} \end{cases} \quad (6.1.4)$$

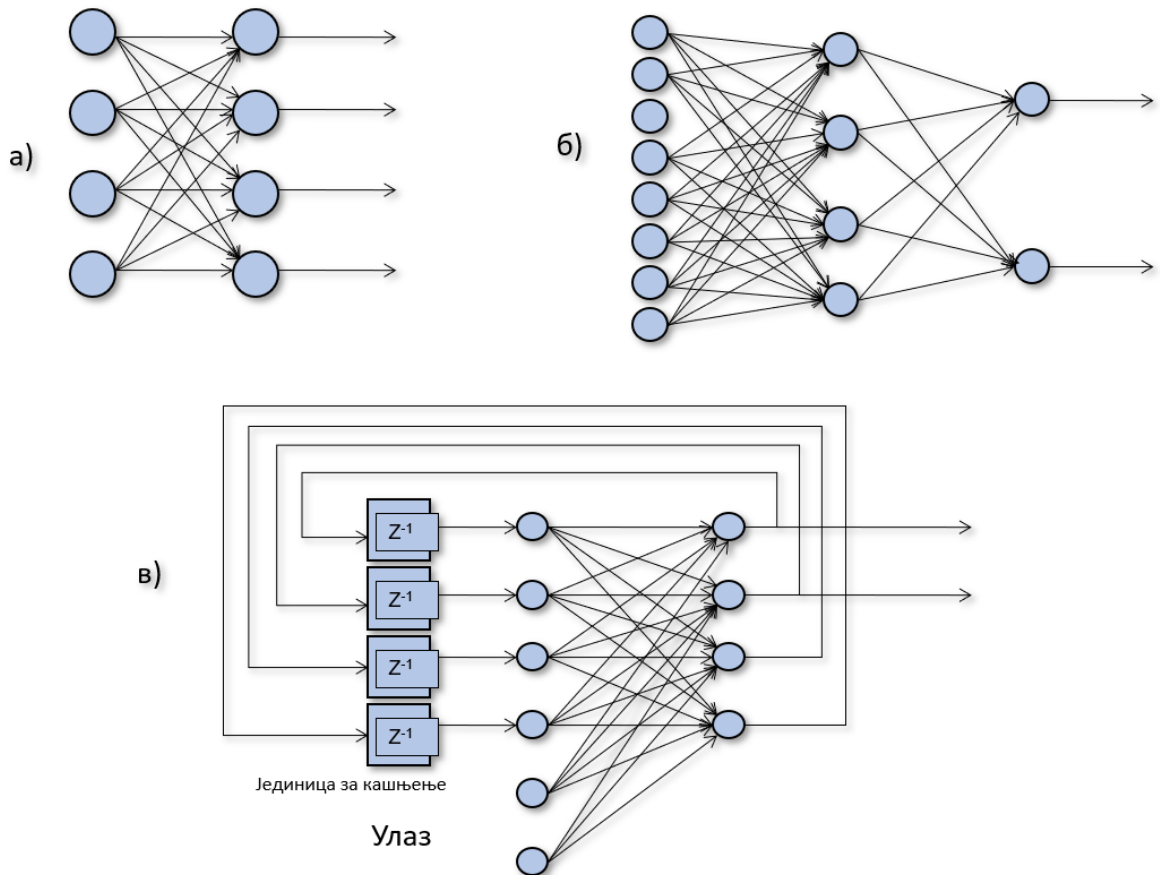
$$y_k = f(u_k) = \frac{1}{1+e^{-au_k}}, \quad [0,1] \quad (6.1.5)$$

При чему је a параметар нагиба логистичке функције.

$$y_k = f(u_k) = \tanh\left(\frac{u_k}{2}\right) = \frac{1-e^{-u_k}}{1+e^{-u_k}}, \quad [-1,1] \quad (6.1.6)$$

$$y_k = f(u_k) = e^{-x^2} \quad (6.1.7)$$

Друга важна особина вештачких неуронских мрежа је начин на који су оне повезане и класификација на основу повезаности. Стога, разликујемо једнослојне (Слика 18а), вишеслојне (Слика 18б), рекурентне (Слика 18в), бочно повезане и хибридне неуронске мреже. У сврхи предвиђања квалитета доживљаја изабрана је вишеслојна структура о којој ће бити речи у даљем тексту.



Слика 18 - Архитектура неуронских мрежа а) једнослојне б) вишеслојне и в) рекурентне неуронске мреже

Вишеслојне неуронске мреже поседују улазни слој чворова за пријем улазних података и излазни слој чворова. Осим улазног и излазног слоја чворова, вишеслојне

неуронске мреже садрже и један или више процесних међучворова – *скривени слој*. Скривени слојеви немају непосредну везу са окружењем мреже и нису повезани на истом слоју, њихов излаз представља улаз за неуроне следећег слоја. Смер кретања вишеслојних неуронских мрежа је увек од улаза преко скривеног слоја ка излазу из мреже. С обзиром да не садрже петље вишеслојне неуронске мреже се могу назвати и статичким.

Како би се решио неки проблем употребом вештачких неуронских мрежа потребно је обезбедити улазне податке, узорке, који ће служити као обучавајући скуп. Адаптација тежинских коефицијената на одговарајућим синапсама постиже се специфичним алгоритмима за подешавање обучавајућих вектора x . Уколико се векторима x придруже и вектори жељених вредности излаза онда се добија обука са надзором (енгл. *supervised training*) у супротном уколико се улазни вектори самоподешавају ради се о обуци без надзора (енгл. *unsupervised learning*). Због велике разлике у поставци ова два типа обуке се примењују и на различитим типовима проблема. Тако се обука без надзора обично користи у проблемима класификације великих скупова података или припреми података, а обука са надзором у проблемима када је неопходно израчунати карактеристике неких класа, њихово предвиђање и слично. С обзиром на чињеницу да је циљ дате методологије предвиђања квалитета доживљаја изабрана су два типа вишеслојних неуронских мрежа које се ослањају на обуку са надзором описаних у поглављима „*Вишеслојни перцептрон*“ и „*Неуронска мрежа са радијално базном функцијом*“.

6.1.1 Перцептрон правило обуке

Промена тежинских коефицијената на синапсама довођењем различитих обучавајућих узорака на улаз у мрежу представља обуку вештачких неуронских мрежа. Обука се остварује уз помоћ вишеструког понављања поцеса проласка података за обуку кроз мрежу уз примену изабраног закона обуке. Како би се лакше објаснило перцептрон правило обуке, употребљено у методологији описаној овим докторатом, неопходно је увести основне варијабле, па тако за i -ти нерон тежински фактор означен је са w_i , где w_{ij} представља j -ти улаз преко j -те синапсе датог неурона.

Перцептрон обука је обука са надзором где се сигнал обуке формира као разлика између потребног d_i и стварног излаза неурона y_i описана формулом (6.1.8).

$$r = d_i - y_i \quad (6.1.8)$$

$$y_i = \text{sqn}(w_i^T x) \quad (6.1.9)$$

Промена на вектору тежина синапси за i -ти нерон за случај сигнум активационе функције:

$$\Delta w_i = \eta (d_i - \text{sqn}(w_i^T x)) x \quad (6.1.10)$$

А промена појединих синапси се може онда описати формулом (6.1.11) узимајући у обзир промене на вектору тежинских синапси за i -ти нерон:

$$\Delta w_{ij} = \eta (d_i - \text{sqn}(w_i^T x)) x_j \quad \text{за } j = 1, 2, \dots, n \quad (6.1.11)$$

6.1.2 Делта правило обуке

Делта правило обуке или метод корекције грешке припада методама обуке вештачких неуронских мрежа са надзором. Ово правило обуке се искључиво користи за неуроне са континуалном активационом функцијом. Делта правило обуке има за циљ да се стварни излаз из неурона приближи жељеним излазима. Функција се формира као сума квадрата грешке. Грешка је представљена као разлика између жељеног и стварног излаза (6.1.12)

$$E = \frac{1}{2} (d_i - y_i)^2 \quad (6.1.12)$$

Ако се замени да је активациона функција неурона једнака стварном излазу (6.1.13)

$$E = \frac{1}{2} (d_i - f(w_i^T x))^2 \quad (6.1.13)$$

Деривацијом критеријумске функције (6.1.12) добија се делта правило обуке, па је вектор градијента грешке дат формулом (6.1.14), а поједине компоненте дате формулом (6.1.15)

$$\nabla E = -(d_i - y_i) f'(w_i^T x) x \quad (6.1.14)$$

$$\frac{\partial E}{\partial w_{ij}} = -(d_i - y_i)f'(w_i^T x)x_j, j = 1, 2, \dots, n \quad (6.1.15)$$

Минимизација грешке доводи до негативног градијентног правца промене тежинских коефицијената на синапси

$$\Delta w_i = -\eta \nabla E \quad (6.1.17)$$

где је η позитивна константа – коефицијент обуке. Делта сигнал дат је обликом (6.1.18)

$$r = [d_i - f(w_i^T x)]f'(w_i^T x) \quad (6.1.18)$$

Промена вектора тежине синапси добија се изразом (6.1.19)

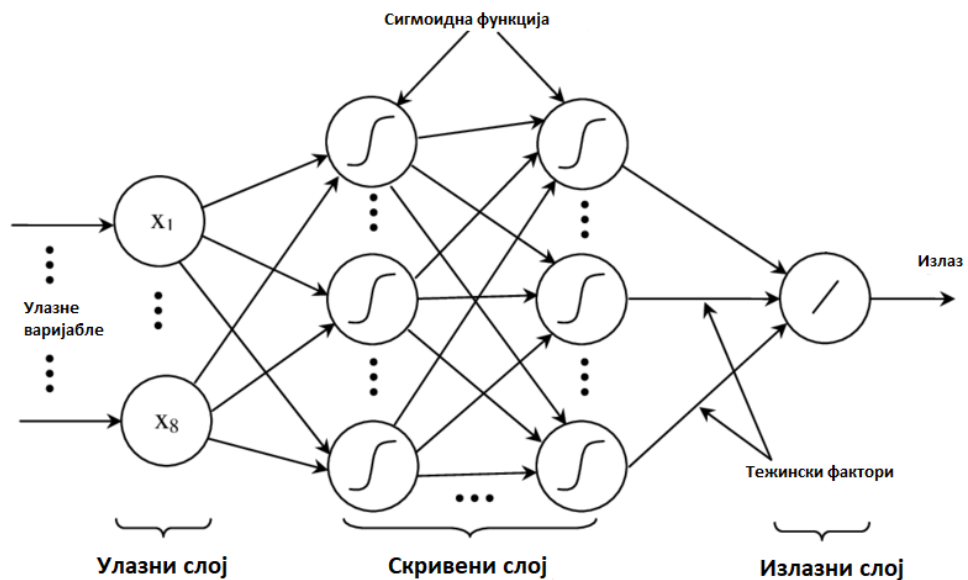
$$\begin{aligned} \Delta w_i &= \eta(d_i - y_i)f'(w_i^T x)x \\ \Delta w_{ij} &= \eta(d_i - y_i)f'(w_i^T x)x_j, j = 1, 2, \dots, n \end{aligned} \quad (6.1.19)$$

Површ грешке у зависности од промене тежине на синапсама дата је мултидимензијалном површи и уколико се користи нелинеарна активациона функција, као у случају методологије описане овом дисертацијом, има више минимума

6.1.3 Вишеслојни перцептрон

Вештачка неуронска мрежа је једна од најбољих структура за решавање различитих проблема који се односе на вештачку интелигенцију, препознавање облика, класификацију, предикцију временских серија и многе практичне проблеме. Организацијом више перцептрона у слојеве може се направити вишеслојни перцептрон – вештачка неуронска мрежа са надзором намењена широком спектру употребе. Вишеслојни перцептрон је најчешће коришћен облик вештачке неуронске мреже. На Слици 19 дата је структура вишеслојног перцептрона. Типично, састоји се од неколико слојева неурона. Вишеслојни перцептрон може се састојати од најмање три и више слојева, при чему први слој увек представља улазни слој, а последњи слој – излазни слој мреже. Између се налази један или више скривених слојева. На улазном слоју налазе се неурони који су повезани синапсама, а

на скривеном и излазном слоју налазе се процесорски неурони - перцептрони. Обично је довољно 2 скривена слоја за сложена обраду података. Улаз се простире преко заједничких синапси преко претходног слоја који се даље прослеђују неуронима на следећем слоју. У овом процесу се улазни сигнали трансформишу у сваком неурону употребом нелинеарне и непрекидне активационе функције на неурону. Уколико је сигнал пропагиран од улаза ка излазу онда је овај тип мреже тзв. *feedforward* неуронска мрежа. Да би били одређени параметри ове мреже, потребно је минимизирати функцију грешке.



Слика 19 – Пример вишеслојног перцептрона

Режим рада неуронске мреже почиње процесом обучавања, а завршава се процесом експлоатације. Приликом обучавања минимизација грешке излаза постиже се кориговањем тежинских коефицијентима на везама неурона суседних слојева, док се за време експлоатације сигнал не коригује приликом проласка. Најчешћи поступак обуке мреже је метода повратне грешке (енгл. *backpropagation*). Ова метода заснована је на претходно објашњеном генерализованом делта правилу.

Поступком поватне грешке пролази се кроз две фазе. У првој фази тежински фактори на синапсама се не мењају, него се подаци простиру кроз све неуроне од улазног слоја до излазног слоја. Излаз сваког неурона добија се израчунавањем сигмоидне функције која се може приказати (6.1.19).

$$out_i^{(k)} = \frac{1}{1+e^{-in_i^{(k)}}} \quad (6.1.19)$$

Приказана за i -ти неурон на k -том слоју. Ниво интерне мрежне активности i -тог неурона на k -том слоју је

$$in_i^{(k)} = \sum_j w_{ij}^{(k)} out_j^{(k-1)} \quad (6.1.20)$$

Грешка излаза добија се као разлика између коначног излаза и жељеног излаза. Грешка E може се изразити формулом (6.1.21) ако се вредност израза свих неурона излазног слоја означи вектором y , а жељена вредност излаза са d

$$E = \frac{1}{2} \sum_i (d_i - y_i)^2 \quad (6.1.21)$$

Друга фаза обуке резервисана је за корекцију тежинских коефицијената синапси пролазом кроз неуронску мрежу слој по слој у супротном смеру. Методом опадајућег градијента врши се минимизација суме квадрата грешака излаза E приликом пролаза у супротном смеру, па се сада корекција тежинских фактор израчунава као

$$w'_{ij} = w_{ij} + \Delta w_{ij} \quad (6.1.22)$$

где су w'_{ij} кориговане вредности тежина између i -тог неурона произвољних j -тих неурона из претходног слоја, а Δw_{ij} је њихова корекција.

Вишеслојни перцептрон се одликује карактеристиком да сваки неурон садржи нелинеарност која испуњава услове непрекидне диференцијабилности, затим због постојања скривених слојева који не припадају ни улазном ни излазном слоју могуће је адаптират мрежу за решавање веома сложених проблема. Вишеслојни перцептрон препознатљив је по веома високом нивоу повезаности између неурона на суседним слојевима. Вишеслојни перцептрон је по својој природи глобални апроксиматор.

6.1.4 *Levenberg–Marquardt* алгоритам

Како би се детаљније описао *Levenberg–Marquardt* алгоритам неопходно је објаснити алгоритам опадајућег градијента. Метод опадајућег градијента је оптимизациона техника којом се минимизују вредности параметара у правцу супротном (негативном) градијенту дате функције. Опадајући градијент је метод за проналажење минимума једноставних функција и може се рећи да је веома конвергентан. За оптимизацију користи прве изводе функције грешака по параметрима модела те представља алгоритам првог реда. Овим алгоритмом прво се рачунају први изводи грешака, а тежине се подешавају у итерацијама, тежински фактори подешавају се по правцу опадајућег градијента, при чему се грешка пропагира уназад као што је то објашњено у претходном поглављу. Карактеристично за овај метод је да је релативно спор. Спорост алгоритма произлази из чињенице да уместо израчунавања глобалног минимума, решења могу бити заробљена у једном од локалних минимума.

Линеарна комбинација опадајућег градијента и *Gauss-Newton* метода позната је као *Levenberg–Marquardt* алгоритам још познат као метод дампинг (пригушених) најмањих квадрата (енгл. *damped least-squares*). Обе методе су оптимизациони алгоритми за решавање проблема минимизације параметара, засноване на методу најмањих квадрата. Због тога што поред опадајућег градијента користи и *Gauss-Newton* метод, даје далеко ефикасније решење за конвергенцију и оптимизацију. *Gauss-Newton* метод подразумева да је грешка квадратна у околини оптималног решења, што је базирано на Тејлоровој апроксимацији другог реда грешке суме квадрата. Лакше решавање проблема конвергенције, а пре свега смањено трајање рачунарских процеса је стога карактеристика комбинације *feedforward* неуронске мреже и *Levenberg–Marquardt* алгоритама – вишеслојног перцептрона.

Смењивањем опадајућег градијента и *Gauss-Newton* метода настаје дампинг стратегија, подешавање параметара која је контролисано дампинг фактором λ . Када је дампинг фактор велики алгоритам се понаша као опадајући градијент у супротном као *Gauss-Newton* метод.

Подешавање параметара *Levenberg–Marquardt* алгоритама одвија се по корацима:

1. улазни сигнал се пропагира ка излазу
2. израчунају се резидуали - разлика између тачне и предпостављене вредности одбирка сигнала

3. примењује се оптимизациони алгоритам променом параметара уназад
4. уколико је оптимизациони критеријум задовољен обучавање се зауставља, у супротном се изводи минимизација корак по корак до задовољавања оптимизационог критеријума.

Може се закључити да је *Levenberg–Marquardt* алгоритама итеративни метод, који је бољи од метода опадајућег градијента и *Gauss-Newton* метода појединачно јер користи њихову комбинацију, али захтева више меморије за израчунавање. С обзиром да је у случају оптималне количине података већа количина употребљене меморије незнатна ова метода изабрана је за тренирање вишеслојног перцептрона, а детаљи су дати у поглављу „*Метода и фазе истраживања*“

6.2 Неуронске мреже са општом регресијом

Неуронске мреже са радијално базном функцијом (енгл. *Radial Basis Neural Networks*) су универзални апроксиматори и представљају вештачке неуронске мреже без повратних веза баш као и вишеслојни перцептрон. Оне се разликују од вишеслојног перцептрона јер обично садрже само један скривени слој, затим њихове активационе функције на скривеном и излазном слоју су различите. На скривеном слоју активационе функције су нелинеарне радијално базне функције, а на излазном линеарне. Код неуронске мреже са радијално базном функцијом неурони на скривеном слоју рачунају Еуклидово растојање између улазног вектора и центра дате функције. Ове мреже су по својој природи локални апроксиматори нелинеарног улазно-излазног пресликавања.

Варијација неуронских мрежа са радијално базном функцијом назива се општа (генерализована) регресиона неуронска мрежа (енгл. *General Regression Neural Network*) која ће се користити као упоредни естиматор вишеслојном перцептрону у даљем тексту. Генерализоване регресионе неуронске мреже су, такође *feedforward* неуронске мреже које су засноване на обуци са надзором. Оне спадају у статистичке неуронске мреже јер углавном зависе од статистичких метода и теорија вероватноће. Могу се користити за регресију, предвиђање и класификацију, као и добро решење за онлајн динамичке системе. Генерализована регресиона неуронска мрежа представља побољшану технику у неуронским мрежама засновану на непараметријској регресији. Идеја је да ће сваки узорак тренинга представљати средину за радијални основни неурон. Ове мреже су познате по

својој способности да тренирају брзо на ретким скуповима података. Уместо да категоризују податке попут радијално базних неуронских мрежа, генерализоване регресионе неуронске мреже су способне да производе континуирано вредноване резултате. Важан нуспроизвод генерализоване регресионе неуронске мреже је *Bayesian* најмања вероватноћа.

Обука генерализоване регресионе неуронске мреже је врло рапидна јер се подаци простиру само унапред, за разлику од *back-propagation* неуронских мрежа, где се подаци пропагирају напред и назад онолико пута колико је потребно да се пронађе прихватљива грешка.

Генерализоване регресионе неуронске мреже се показују добро на проблемима интерполације. Међутим, будући да су апроксиматори функција, теже да мењају тачност за брзину. Ове мреже се користи и за процену континуитета променљиве, као у стандардним техникама регресије. Генерализована регресиона неуронска мрежа користи једну заједничку радијалну основну функцију ширина појаса језгра (σ) која је подешена да постигне оптимално учење. Регресија коју извршава генерализована регресиона неуронска мрежа је заправо условно очекивање Y . Другим речима, он даје највероватнији скалар Y у односу на задати улазни вектор x .

Нека је $f(x, y)$ заједничка континуирана функција густине вероватноће векторске случајне променљиве X и скалара случајне променљиве Y , при чему је x одређена измерена вредност случајног X . Регресија (условна средина) Y за дато x описана је формулом (6.1.23)

$$E[Y/x] = \int_{-\infty}^{\infty} Y \cdot f\left(\frac{Y}{x}\right) dx = \frac{\int_{-\infty}^{\infty} Y \cdot f(x, Y) dy}{\int_{-\infty}^{\infty} f(x, Y) dy} \quad (6.1.23)$$

Ако се однос између независних X и зависних Y променљивих изрази у функционалном облику са параметрима, тада ће регресија бити параметарска. У супротном ако се за однос независних искористи један од конзистентних проценитеља, *Gaussian* функција онда је то непараметарска процена. Овај естиматор је добар избор за процену функције густине вероватноће, ако се може претпоставити да је основна густина континуирана и да су први делимични изводи функције процењени на било ком x мали. Дobar избор за процењивач вероватноће заснован на вредностима узорка x и y случајних променљивих X и Y дат је:

$$\hat{f}(x, y) = \frac{1}{(2\pi)^{\frac{(p+1)}{2}} \sigma^{p+1}} \cdot \frac{1}{n} \sum_{i=1}^n \left\{ \exp \left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2} \right] \exp \left[\frac{(y-y_i)^2}{2\sigma^2} \right] \right\} \quad (6.1.24)$$

При чему је p димензија векторске променљиве, n је број парова за тренинг $(x_i \rightarrow y_i)$, σ појединачни параметар за учење, Y жељени скаларни излаз у односу на посматрани улаз x_i .

Генерализована регресиона неуронска мрежа састоји се од четири слоја. Први слој је улазни слој који је у потпуности повезан са другим слојем и служи за пропацију улазних узорака.

Други слој је први скривени слој. Овај слој се састоји од N обрађивачких елемената или чворова, при чему је N број узорака тренинг сета и сваки чвор представљен је улазним вектором, повезан са вектор додељен j -тим узорком у подацима о обуци. У сваком чвору се улазни вектор одузима од вектора додељеног чвору, а затим ова разлика постаје квадратна. Резултат се доводи у нелинеарно језгро, које је обично експоненцијална функција. Излази се затим доводе до јединица за сабирање - трећег слоја (другог скривеног слоја). Трећи слој се састоји од два чвора. Улаз у први чвор је збир првих излаза скривеног слоја, сваки пондерисан посматраним излазом x_j који одговара X_j . Улаз другог чвора је сума активације првог скривеног слоја. Четврти слој је излазни слој. Прима два излаза из другог скривеног слоја и дели их да би се добио резултат предвиђања.


У архитектури ових мрежа, за разлику од других мрежних архитектура, нема обуке параметара као што су стопа учења и импулс, али постоји фактор учења σ , неретко називан фактор „заглађивања“. Он се примењује на мрежу након обуке мреже, а његов избор је веома важан јер се користи за изравнавање узорака тренинга. Мале вредности овог фактора теже ка томе да свака тачка тренинга постаје различита, док велике вредности намећу већи степен интерполације између запажања тренинга. Фактор учења мора бити већи од 0 и обично може да се креће од 0,01 до 1.

6.3 Метод регресије потпорних вектора - *Support Vector Regression SVR*

Метод потпорних вектора (енгл. *Support Vector Machine SVM*) је популаран алат за машинско учење у проблемима класификације и регресије. Проблем регресије је уопштавање проблема класификације, у којем модел враћа излаз континуиране вредности, за разлику од резултата коначног скупа. Другим речима, регресијски модел процењује

мултиваријантну функцију континуиране вредности. Метода потпорних вектора за решавање проблема регресије (енгл. *Support Vector Regression* у даљем тексту *SVR*) се сматра непараметријском техником јер се ослања на функције језгра.

SVR решава бинарне проблеме класификације формулишући их као конвексне проблеме оптимизације. Проблем оптимизације подразумева проналажење максималне маргине која раздваја хиперраван, док се правилно класификује што је више могуће тачака тренинга. *SVR* представља ову оптималну хиперравни са потпорним векторима. Оскудно решење и добра генерализација *SVR* могу се прилагодити проблемима регресије као што је приказано на Слици 20. Генерализација *SVR* -а на *SVR* постиже се увођењем епсилон региона око функције, названог епсилон област око равни. Ова епсилон област преформулише проблем оптимизације како би пронашла област која најбоље приближава функцију континуиране вредности, истовремено балансирајући сложеност модела и грешку предвиђања. Прецизније, *SVR* је формулисан као проблем оптимизације тако што најпре дефинише конвексну епсилон-неосетљиву функцију губитка која се минимизира и проналази најравнију област која садржи већину примера тренинга. Затим се решава конвексна оптимизација која има јединствено решење, користећи одговарајуће алгоритме нумеричке оптимизације. Хиперраван је представљена у виду потпорних вектора, који су узорци за обуку који леже изван границе области. Као и у случају *SVR*, потпорни вектори *SVR* су најугицајнији случајеви који утичу на облик области, а претпоставља се да су подаци о тренингу и испитивању независни и идентично распоређени изведени из исте фиксне, али непознате функције расподеле вероватноће у контексту надгледаног учења.



Слика 20 - Формулација *SVR* из геометријске перспективе

Иако мање популаран метод од *SVM*, *SVR* се показао као ефикасан алат у процени функције стварне вредности. Као приступ са надзором, *SVR* тренира користећи функцију симетричног губитка, што подједнако погађа високе и ниске вредности. Формулацију *SVR* проблема често је најбоље извести из геометријске перспективе, користећи једнодимензионални пример.

Функција континуиране вредности која се апроксимира може се записати као

$$y = \sum_{j=1}^M w_j x_j + b, y, b \in \mathbb{R}, x, w \in \mathbb{R}^M \quad (6.4.1)$$

где је M степен полинома којим се апроксимира функција, w је вектор тежине хиперравни, параметар b одређује помак хиперравнине од исходишта дуж нормалног вектора. *SVR* формулише овај проблем апроксимације функције као проблем оптимизације покушавајући да пронађе најужу епсилон област, истовремено смањујући грешку предвиђања, односно растојање између предвиђених и жељених резултата.

6.4 Редукција димензије модела

У сврху редукције димензије модела са вештачким неуронским мрежама неопходно је увести приступе селекција и издвајање обележја. Селекција обележја односи се на методе које уклањају све ирелевантне и редундантне величине из скупа улазних података, при чему издвојене величине задржавају све своје физичке особине, а мерни простор је само мањег реда.

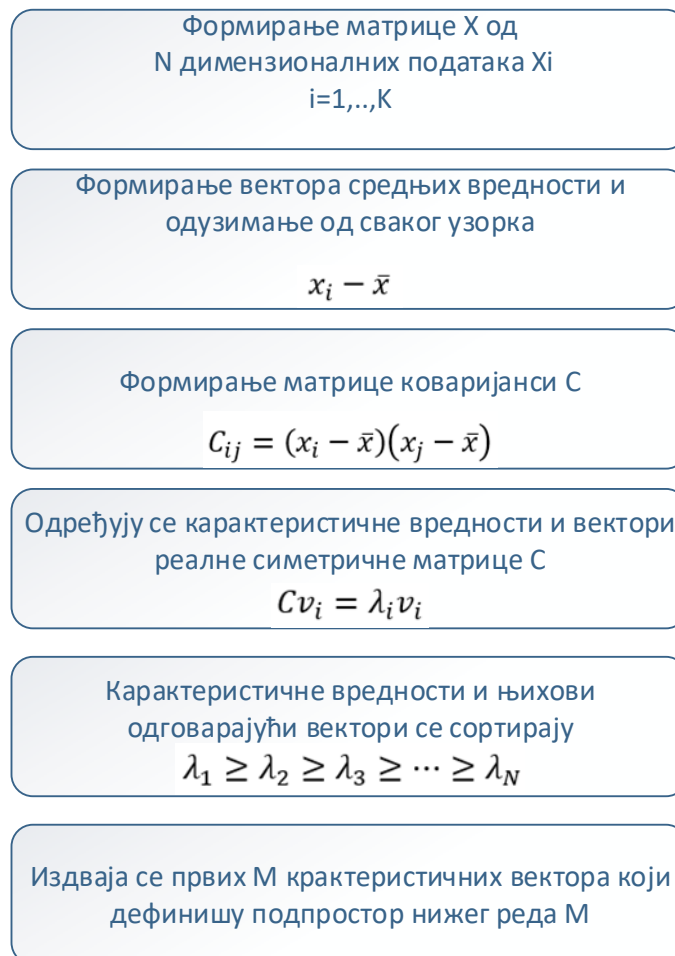
Селекцију обележја можемо поделити на филтрирајуће или комбинујуће методе и то у зависности од критеријума који се користи приликом селекције. Тако филтрирајуће методе користе карактеристичне особине узорака података за оцену или евалуацију као што су ентропија или корелација. Познате корелационе методе су проналажење *Perason* и *Speratan* корелационих фактора. Обе методе биће употребљене у сврху селекције обележја методологије дате дисертацијом. Комбинујуће методе мере оцену подскупа употребом грешке класификације.

Осим описаних метода редукције димензионалности, користе се и методе које трансформишу простор улазних величина у потпуно нови простор мањег реда чије компоненте не морају имати полазни смисао [97] као што су методе математичког програмирања и то декомпозиција проблема на сет мањих проблема, сепарације,

дуализације итд. Још специфичнији начин издвајања обележја чине неке врсте неуронских мрежа које користе метод екстракције кључних карактеристика система. У дисертацији биће употребљена конвенционална метода заснована на мултиваријабилној статистичкој анализи метода за редукцију димензионалности издвајањем обележја - анализа базних компоненти (енгл. *Principal component analysis* PCA).

6.4.1 Анализа базних компоненти

Анализа базних компоненти је метода којом се скуп корелисаних променљивих трансформише у некорелисане променљиве уз услов да је број корелисаних променљивих увек већи или једнак некорелисаним. Овим методом рачунањем карактеристичних вектора коваријансе матрице података одређују се базне компоненте оригиналних података, а значај појединих карактеристичних вектора одређен је величином одговарајуће карактеристичне вредности. Кораци методе анализе базних компоненти дати на Слици 21.



Слика 21 – Кораци методе анализе независних компоненти

Прорачун карактеристичних вредности и карактеристичних вектора обавља се тако што се матрица коваријанси декомпонује

$$C = V\Lambda V^T \quad (6.2.1)$$

при чему је Λ дијагонална матрица карактеристичних вредности, а V ортогонална матрица која се формира од свих карактеристичних вектора тачније матрица ротације ортогоналног координатног простора у простору карактеристичних вектора. Једначина се решава употребом рутине декомпозиције сингуларних вредности или *Householder-QR* трансформацијом. Метод анализе базних компоненти може се применити само на подацима са нормалном дистрибуцијом при чему оса са највећим варијансама одговара корисним променљивима, а оса са малим потиче од шума. Редукција оса са малим варијансама повећава тачност.

6.5 Пеарсон и Спearман корелација

Статистичка мера за одређивање односа и степена сличности између две варијабле позната је као корелација. Однос може бити изразит до слабог те се мера сличности може изразити помоћу коефицијента сличности – коефицијента корелације. Корелациони коефицијент варира у опсегу између -1.00 и +1.00, а његова вредност говори о томе колико су две варијабле сличне. Ако је коефицијент корелације близу ± 1.00 значи да су варијабле изузетно корелисане, тачније постоји јака повезаност. Позитивна вредност говори о позитивној повезаности односно да су високе вредности прве варијабле повезане са високим вредностима друге, а ниске са ниским. Негативна вредност указује на супротну негативну повезаност односно да су високе вредности прве варијабле повезане са ниским вредностима друге и обрнуто. Уколико вредност коефицијента конвергира ка нули може се рећи да вредности једне варијабле не говоре ништа о вредностима друге те нису корелисане и немају никакве повезаности.

Пеарсонов (енгл. *Pearson*) коефицијент корелације је коваријанса две променљиве подељена умношком њихових стандардних одступања. Облик дефиниције укључује „моменат производа“, односно средњу вредност производа средње вредности прилагођених случајних променљивих. Пеарсонов коефицијент корелације, када се примењује на узорак, обично се представља као r_{xy} . За n парова варијабли $\{(x_1, y_1), \dots, (x_n, y_n)\}$, r_{xy} се може дефинисати као:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (6.3.1)$$

при чему је n величина узорка, а x_i и y_i независне варијабле а

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (6.3.2)$$

и

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (6.3.3)$$

средња вредност варијабли.

Даљим математичким заменама може се доћи до формуле (6.3.4). Еквивалентни израз даје формулу као средњу вредност производа стандардних оцена, па следи:

$$r_{xy} = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right) \quad (6.3.4)$$

где су (6.3.5) и (6.3.6) стандардна оцена узорака

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (6.3.5)$$

$$s_y = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (6.3.6)$$

Сpearманов (енгл. *Spearman*) коефицијент корелације или Сpearманов ρ , процењује колико добро се однос две променљиве може описати помоћу монотоне функције. Сpearманова корелација између две променљиве једнака је Пеарсоновој корелацији између вредности ранга те две променљиве. Док Пеарсонова корелација процењује линеарне везе, Сpearманова корелација оцењује монотоне односе. Ако нема поновљених вредности података, јавља се савршена Сpearманова корелација +1.00 или -1.00 када је свака од променљивих савршена монотона функција друге. Сpearманова корелација између две променљиве биће висока када посматрања имају сличан ранг (тј. ознака релативног положаја запажања унутар променљиве) између две варијабле и низак када посматрања

имају различит (или се потпуно супротставља корелацији -1) ранг између две променљиве. За узорак величине n , X_i и Y_i конвертују у ранкове rg_x и rg_y

$$r_s = \frac{cov(rg_x, rg_y)}{\sigma_{rg_x} \sigma_{rg_y}} \quad (6.3.7)$$

Где је $cov(rg_x, rg_y)$ коваријанса вредности ранкова а σ_{rg_x} и σ_{rg_y} стандардне девијације вредности ранкова.

Осим обичне корелације две варијабле битан статистички алат је и унакрсна корелације (енгл. *cross-correlation*) која се користи за проучавање међусобне зависности два сигнала и кватификује степен линеарне повезаности два стационарна случајна процеса.

7 Метода и фазе истраживања

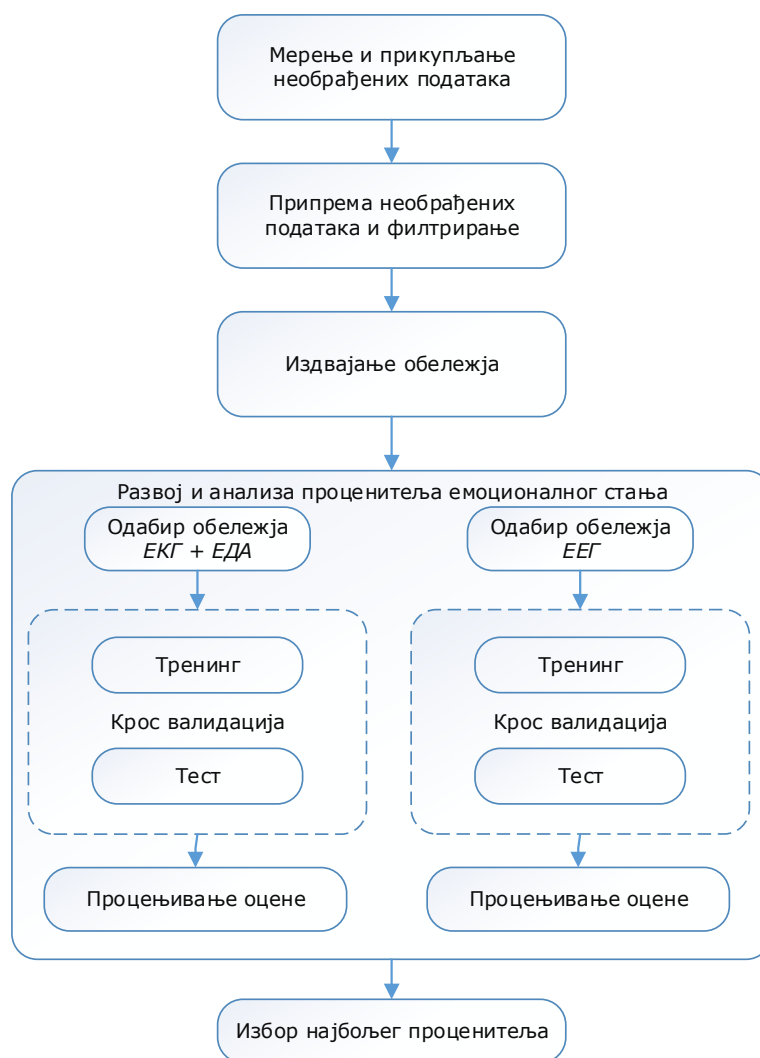
У наставку се предлаже специфичан модел за процену човековог емоционалног стања током гледања стереоскопског 3Д видео записа. Главни фокус рада није на техници машинског учења већ на начину на који се проблем моделује. Модел је организован на следећи начин. Прво се прикупљају сирови психо-физиолошки подаци, укључујући ECG, EDA и EEG сигнале од 18 учесника. Волонтери су 12 жена и 6 мушкараца старих између 18 и 33 године ($M = 22,72$, $STD = 4,27$), регрутовани у кампусу где је вршено прикупљање података. Прва фаза је мерење и прикупљање сирових података са електрода, као и субјективних оцена. ECG и EDA сигнали прикупљају се помоћу две електроде директно постављене на грудни кош, односно прсте. EEG сигнали, прикупљени путем 14-каналног уређаја *Emotiv Epos*, састоје се од различитих делова опсега спектра и можданих региона. База података и прикупљање психо-физиолошких података описани су у одељку *“Опис базе података”*. Заједно са психо-физиолошким сигнаlima, прикупљени су и резултати самопроцене емоционалног стања. Мерења су објашњена у одељку *„Мерење квалитета доживљаја“*.

Након прикупљања свих података, на основу претпоставке да дистрибуција оцена следи нормалну дистрибуцију, параметри који одскачу (енгл. *outliers*) се уклањају помоћу правила 3-сигма, а смањена база података се претходно обрађује помоћу нископропусног филтра. Сви детаљи могу се наћи у одељку *„Припрема необрађених података и филтрирање“*. Такви филтрирани подаци користе се за другу фазу, *„Издавање обележја“*. У другој фази се тако сакупљени подаци филтрирају и припремају како би најбоље одговарали даљој обради. Из тако обимног скупа података уз помоћ пажљиво одабраних математичких метода издвајају се релевантна обележја. У фази екстракције обележја карактеристике HR и EDA издвојене су математичким методама за екстракцију прорачуна густине вероватноће: средње вредности, медијане, стандардне девијације, трећег и четвртог момента густине вероватноће. Екстракција обележја EEG сигнала користи исте прорачуне са малом разликом. Разлика је у томе што се резимирају само прва три израчунавања густине вероватноће: средња, медијана и стандардна девијација. Одлука да се смањи издвајање особина на прве три ставке густине вероватноће донета је зато што је EEG скуп обележја много опсежнији и прецизнији од HR и EDA, па је количина издвојених обележја довољна. С друге стране, користи се такво основно издвајање EEG својстава, јер су

одређени таласи и региони у којима се јављају доследно повезани са одређеним психолошким процесом, па посебно издвајање није потребно.

Затим се у следећој фази израђује и анализира проценитељ стања тако што се од издвојених обележја прво извршава селекција обележја. Три редукована скупа издвојених обележја HR, EDA и EEG се генеришу комбинујући неколико приступа избор обележја (енгл. *feature selection*) детаљно објашњених у одељку „Одабир обележја“.

Затим се конструише вештачка неуронска мрежа или нека друга техника машинског учења која на својим улазима има селектована обележја. Изабрани метод машинског учења се тренира улазним подацима, па проверава крос валидацијом и тестирањем.



Слика 22 - Степ дијаграм предложене методологије

Излази из система су процењене оцене квалитета доживљаја тачније емоционалног стања. Број улаза у систем се варира како би се нашао оптималан скуп обележја. Конструисане неуронске мреже, као свој улаз имају све комбинације карактеристика из сваког од редукованих скупова карактеристика. Тада се генеришу мрежне конфигурације комбиновањем карактеристика из HR, EDA и EEG смањених скупова. Резултати самопроцене користе се као циљане вредности за процену. Вишеслојни перцептрон користи се као алгоритам за машинско учење за процену, чија је поставка детаљно описана у одељку „Поставка неуронске мреже“. Да би се проценили перформанси генерисаних конфигурација неуронске мреже, израчунавају се корен средње квадратне грешке, стандардна девијација, Пеарсонова и Спирманова корелација између стварних резултата самопроцене и процењених резултата. На основу измерених перформанси одабрано је неколико конфигурација које су представиле боље перформансе. Коначно, најбољи процењивач се бира променом броја улаза у вишеслојни перцептрон и упоређивањем неколико конфигурација са најбољим перформансама. Слика 22 приказује дијаграм корака предложеног модела.

Због различите природе сигнала издвојена су два паралелна модела, један модел са улазима HR и EDA, а други са улазима EEG. На основу добијених резултата и упоредном анализом са субјективним мерама изабира се најбољи проценитељ.

7.1 Припрема необрађених података и филтрирање

Како би се осигурало да је део модела који се односи на прикупљање објективних мера емотивног стања користан за употребу у процени квалитета доживљаја у 3Д видео садржају, неопходно је осигурати да се сви подаци прикупљају од испитаника у различитим годинама, половима и сл. Међутим, добро је познато да таква испитивања и експерименти могу произвести много необичних података који се морају претходно обрадити за употребу у истраживањима. Такође, када се користе за процену менталних процеса, психо-физиолошки подаци садрже шум (нпр. повезан са индивидуалним разликама или биолошке аспекте који нису повезани са циљним психолошким променљивим) и због тога захтевају припрему. Како би се осигурало да одступања не утичу на податке пре претходне обраде података, одступања су уклоњена помоћу правила 3σ .

Метода претходне обраде и прикупљања или чак стварања корисног скупа података за будуће манипулације први је корак анализе података (енгл. *data mining*). Главна сврха

овог истраживања је употреба постојећег знања о људском емоционалном стању у квалитета доживљаја процени 3Д видео записа употребом техника анализе података и машинског учења, користећи предности техника анализе података у сврху мапирања визуелне нелагодности на различите врсте 3Д садржај и процена емоционалног стања. С обзиром на то да је позната коначна сврха онога што желимо да постигнемо сировим подацима, подаци се припремају како би најбоље одговарали даљој обради у неуронској мрежи. Опсег електрода и природа објективних мера које се бележе дали су нам брзину узорковања од 2000 Hz за прикупљање сирових података. Таква брзина узорковања није погодна за даљу манипулацију и па се због тога брзина узорковања мора смањити 1 Hz уз помоћ нископропусног филтера.

7.2 Издвајање обележја

Издвајање обележја извршено је одвојено за податке HR, EDA и EEG. С обзиром на различиту природу ових мера, исти математички и статистички модели за издвајање обележја не могу се применити на све њих. У случају HR и EDA издвајање особина је изведено помоћу прорачуна за издвајање густине вероватноће као корисне квантитативне мере. На овај начин нула је укупна вероватноћа. Прва карактеристика издвојена као прво обележје је средња вредност, друга медијана, трећа је варијанса или њен квадратни корен - стандардна девијација, четврта карактеристика је трећи статистички моменат – мера асиметричности (енг. *skewness*), а пета је четврти статистички моменат – мера количине одступања у односу на нормалну дистрибуцију (енг. *kurtosis*).

| | Срчани ритам | Електро-дермална активност |
|--------------------|--------------------|----------------------------|
| Издвојена обележја | HR Moving Mean | EDA Moving Mean |
| | HR Mean | EDA Mean |
| | HR Moving Median | EDA Moving Median |
| | HR Median | EDA Median |
| | HR Moving STD | EDA Moving STD |
| | HR STD | EDA STD |
| | HR Moving PCA | EDA Moving PCA |
| | HR PCA | EDA PCA |
| | HR Moving Skew | EDA Moving Skew |
| | HR Skew | EDA Skew |
| | HR Moving Kurtosis | EDA Moving Kurtosis |
| | HR Kurtosis | EDA Kurtosis |
| | - | SCR Mean |
| | - | Number of SCRs |

ТАБЕЛА 6 - СПИСАК СВИХ ИЗДВОЈЕНИХ ОБЕЛЕЖЈА ЗА HR И EDA

Да би се умањио шум присутан у подацима, примењен је покретни прозор за издвајање свих поменутих обележја. Дужина покретног прозора је 10 места. И за HR и за EDA извршена је анализа главне компоненте и екстраховане су главне компоненте.

Поред тога, узете су у обзир и друге карактеристике EDA, попут броја галванских кожных одговора, затим реакција на проводљивост коже (енгл. *skin conductance response SCR*) и промена ниво проводљивости коже, број пикова *SCR* и средња вредност *SCR* за издвајање EDA својстава. Списак свих мера извучених из података о HR и EDA дат је у Табели 6.

Списак мера извучених из EEG кроз груписање на основу регије мозга - чеони, потиљачни и темени режањ дат је у табели 7. Њихово издвајање се заснива на проналажењу средње вредности, медијане и вредности стандардне девијације мерења током целог трајања видео записа за сваки талас измерен у одређеном региону мозак. Познато је да се одређене регије мозга повезују са већ познатим функцијама и догађајима, као и одређени таласи који се јављају, а региони у којима се јављају могу указивати на специфичне аспекте менталног функционисања. Као што се може видети из Табеле 7, узимају се у обзир само три регије мозга. У ова три региона људи могу да перципирају неке догађаје из визуелних стимулуса и пажње, као што је већ приказано у Табели 1 у поглављу „Објективне мере“.

| | Чеони режањ | Потиљачни режањ | Темени режањ |
|--------------------|----------------------|------------------------|-----------------------|
| Издвојена обележја | alpha asym MEAN | occipital alpha MEAN | parietal alpha MEAN |
| | alpha asym MEDIAN | occipital alpha MEDIAN | parietal alpha MEDIAN |
| | frontal alpha MEAN | occipital alpha STD | parietal alpha STD |
| | frontal alpha MEDIAN | occipital beta MEAN | parietal beta MEAN |
| | frontal alpha STD | occipital beta MEDIAN | parietal beta MEDIAN |
| | frontal beta MEAN | occipital beta STD | parietal beta STD |
| | frontal beta MEDIAN | occipital gamma MEAN | parietal gamma MEAN |
| | frontal beta STD | occipital gamma MEDIAN | parietal gamma MEDIAN |
| | frontal gamma MEAN | occipital gamma STD | parietal gamma STD |
| | frontal gamma MEDIAN | occipital theta MEAN | parietal theta MEAN |
| | frontal gamma STD | occipital theta MEDIAN | parietal theta MEDIAN |
| | frontal theta MEAN | occipital theta STD | parietal theta STD |
| | frontal theta MEDIAN | | |
| | frontal theta STD | | |

ТАБЕЛА 7 - СПИСАК СВИХ ИЗДВОЈЕНИХ ОБЕЛЕЖЈА ЗА EEG

Важно је напоменути да се број коришћених узорака разликује у зависности од методе за издвајање карактеристика и њихове природе. Један од разлог зашто се број узорака

разликује за HR и EDA и EEG податке лежи у чињеници да су подаци за HR и EDA узорке изгубљени услед неисправног мерења за 6 учесника. То значи да је за модел HR и EDA број узорака укупно 108. Овај број узорака добија се из чињенице да за три врсте садржаја постоје 3 нивоа визуелне нелагодности за сваког учесника из групе од 12 учесника. За EEG модел, број узорака је укупно 162, што је једнако 18 учесника и исти узорци који се користе за HR и EDA мере. Из Табела 6 и 7 јасно се може уочити да је број издвојених обележја различит у зависности од карактеристике која се мери.

Након издвајања обележја прелази се на фазу развоја проценитеља емоционалног стања, што значи да је прво неопходно одабрати обележја из скупа издвојених обележја.

7.3 Развој и анализа проценитеља емоционалног стања

7.3.1 Одабир обележја

Одабир обележја из скупа већ издвојених обележја представља најбитнији део припреме података јер се у зависности од избора може доћи до различитих резултата процене. Идеја је да се истражи неколико алгоритама за одабир обележја и да се уз помоћ тежинских фактора изабраних варијабли за сваки од алгоритама направи листа сумирањем тежинских фактора и резултата. Осим алгоритама за одабир обележја, број обележја је оптимизован како би се смањило време обраде података од стране неке од техника машинског учења. Пре одабира употребом статистичких метода трећи и четврти статистички моменат екстрахованих обележја искључени су из даљег разматрања због зашумљене природе улазних сигнала и стога нису имали корисне информације за ово истраживање.

Методе и алгоритми за одабир обележја који су употребљени су:

- методе на бази коефицијента корелације;
- метод заједничких узајамних информација (енгл. *joint mutual information*);
- метод минималне редундантности – максималне релевантности (енгл. *minimum redundancy maximum relevance*);
- алгоритам претрагом унапред/уназад (енгл. *greedy forward/backward search*).

ПОГЛАВЉЕ 7 – Метода и фазе истраживања

С обзиром да су два модела испитивана одвојено, HR/EDA и EEG, због различите природе података као што је претходно поменуто, коришћене су различите методе избора карактеристика. Избор карактеристика за HR и EDA модел извршен је на основу ПEARSONОВОГ коефицијента корелације, МИНИМАЛНЕ РЕДУНДАНТНОСТИ – МАКСИМАЛНЕ РЕЛЕВАНТНОСТИ (*mRMR*) и АЛГОРИТАМА ЗАЈЕДНИЧКИХ УЗАЈАМНИХ ИНФОРМАЦИЈА (*JMI*) [11]. Захтев за избор карактеристика била је ОПТИМИЗАЦИЈА БРОЈА УЛАЗА па је број смањен на 3 или 4 карактеристике. Одабир обележја урађен је тако што је употребљена листа приоритета изабраних променљивих за сваки од три алгорита. У све три циљани вектор био је субјективни резултат који су дали учесници. Карактеристике су одабране на основу пресека најбољих резултата које су дали алгоритми, што је био правац за њихов избор као улаз за алгоритам машинског учења. Урађена је потпуна претрага простора карактеристика како би се добио најбољи модел уз помоћ *Weka* алата [11]. Табела 8 сумира одабране карактеристике на основу пресека.

| FEAST MRMR Узбуђење | | FEAST MRMR Задовољство | | FEAST JMI Узбуђење | | FEAST JMI Задовољство | | Pearson correlation Узбуђење | | Pearson correlation Задовољство | |
|------------------------|--------------------|---------------------------|--------------------|-----------------------|--------------------|--------------------------|--------------------|---------------------------------|--------------------|------------------------------------|-----------------|
| 17 | SCR Mean | 16 | EDA PCA | 12 | EDA Median | 12 | EDA Median | 14 | EDA STD | 12 | EDA Median |
| 7 | HR Move PCA | 4 | HR Median | 17 | SCR Mean | 17 | SCR Mean | 12 | EDA Median | 14 | EDA STD |
| 14 | EDA STD | 14 | EDA STD | 18 | Number of SCRs | 18 | Number of SCRs | 17 | SCR Mean | 8 | HR PCA |
| 12 | EDA Median | 3 | HR Move Median | 3 | HR Move Median | 14 | EDA STD | 16 | EDA PCA | 4 | HR Median |
| 5 | HR Move STD | 17 | SCR Mean | 7 | HR Move PCA | 1 | HR Move Mean | 5 | HR Move STD | 2 | HR Mean |
| 3 | HR Move Median | 8 | HR PCA | 4 | HR Median | 7 | HR Move PCA | 4 | HR Median | 5 | HR Move STD |
| 16 | EDA PCA | 15 | EDA Move PCA | 1 | HR Move Mean | 4 | HR Median | 7 | HR Move PCA | 1 | HR Move Mean |
| 9 | EDA Move Mean | 1 | HR Move Mean | 14 | EDA STD | 3 | HR Move Median | 18 | Number of SCRs | 7 | HR Move PCA |
| 1 | HR Move Mean | 7 | HR Move PCA | 15 | EDA Move PCA | 5 | HR Move STD | 6 | HR STD | 17 | SCR Mean |
| 8 | HR PCA | 12 | EDA Median | 16 | EDA PCA | 9 | EDA Move Mean | 8 | HR PCA | 16 | EDA PCA |
| 15 | EDA Move PCA | 9 | EDA Move Mean | 6 | HR STD | 10 | EDA Mean | 11 | EDA Move Median | 18 | Number of SCRs |
| 10 | EDA Mean | 10 | EDA Mean | 5 | HR Move STD | 11 | EDA Move Median | 10 | EDA Mean | 15 | EDA Move PCA |
| 4 | HR Median | 5 | HR Move STD | 9 | EDA Move Mean | 16 | EDA PCA | 9 | EDA Move Mean | 9 | EDA Move Mean |
| 11 | EDA Move Median | 18 | Number of SCRs | 10 | EDA Mean | 2 | HR Mean | 1 | HR Move Mean | 10 | EDA Mean |
| 18 | Number of SCRs | 11 | EDA Move Median | 11 | EDA Move Median | 13 | EDA Move STD | 2 | HR Mean | 11 | EDA Move Median |
| 2 | HR Mean | 2 | HR Mean | 2 | HR Mean | 8 | HR PCA | 3 | HR Move Median | 6 | HR STD |
| 13 | EDA Move STD | 13 | EDA Move STD | 8 | HR PCA | 15 | EDA Move PCA | 13 | EDA Move STD | 3 | HR Move Median |
| 6 | HR STD | 6 | HR STD | 13 | EDA Move STD | 6 | HR STD | 15 | EDA Move PCA | 13 | EDA Move STD |

ТАБЕЛА 8 – ОДАБРАНА ОБЕЛЕЖЈА МОДЕЛА HR/EDA

Одабир обележја *EEG* сигнала се мора урадити на другачији начин у односу на претходна два случаја, *HR* и *EDA*, и то због њихове различите природе. Међутим, издвајање

обележја *EEG* сигнала је једноставније и заснива се само на проналажењу средње вредности, медијане и вредности стандардне девијације током читавог трајања видеа за сваки талас мерен у одређеном режњу мозга. Овако основна екстракција обележја се користи због познате чињенице да одређени таласи и режњеви у којима се они јављају указују на одређено емоционално стање и специјална издвајања не би допринела већој количини информација, те за њима нема потребе. Осим тога од важности за ово истраживање су само три режња мозга, па ће се само та обележја узети у обзир. Разлог је у томе што су само ова три режња заслужна за догађаје у зависности од визуелног надражаја.

Издвојене *EEG* карактеристике током читавог трајања видео записа за сваки талас мерен у одређеном пределу мозга одабрани су на основу Пеарсоновог коефицијента корелације усмереног на прикупљање субјективних мера. Будући да су резултати били врло слични за средњу вредност, медијану и стандардну девијацију, донета је одлука да се користе само медијана обележја, јер су она дала мало боље резултате.

Списак изабраних карактеристика приказан је у Табели 9.

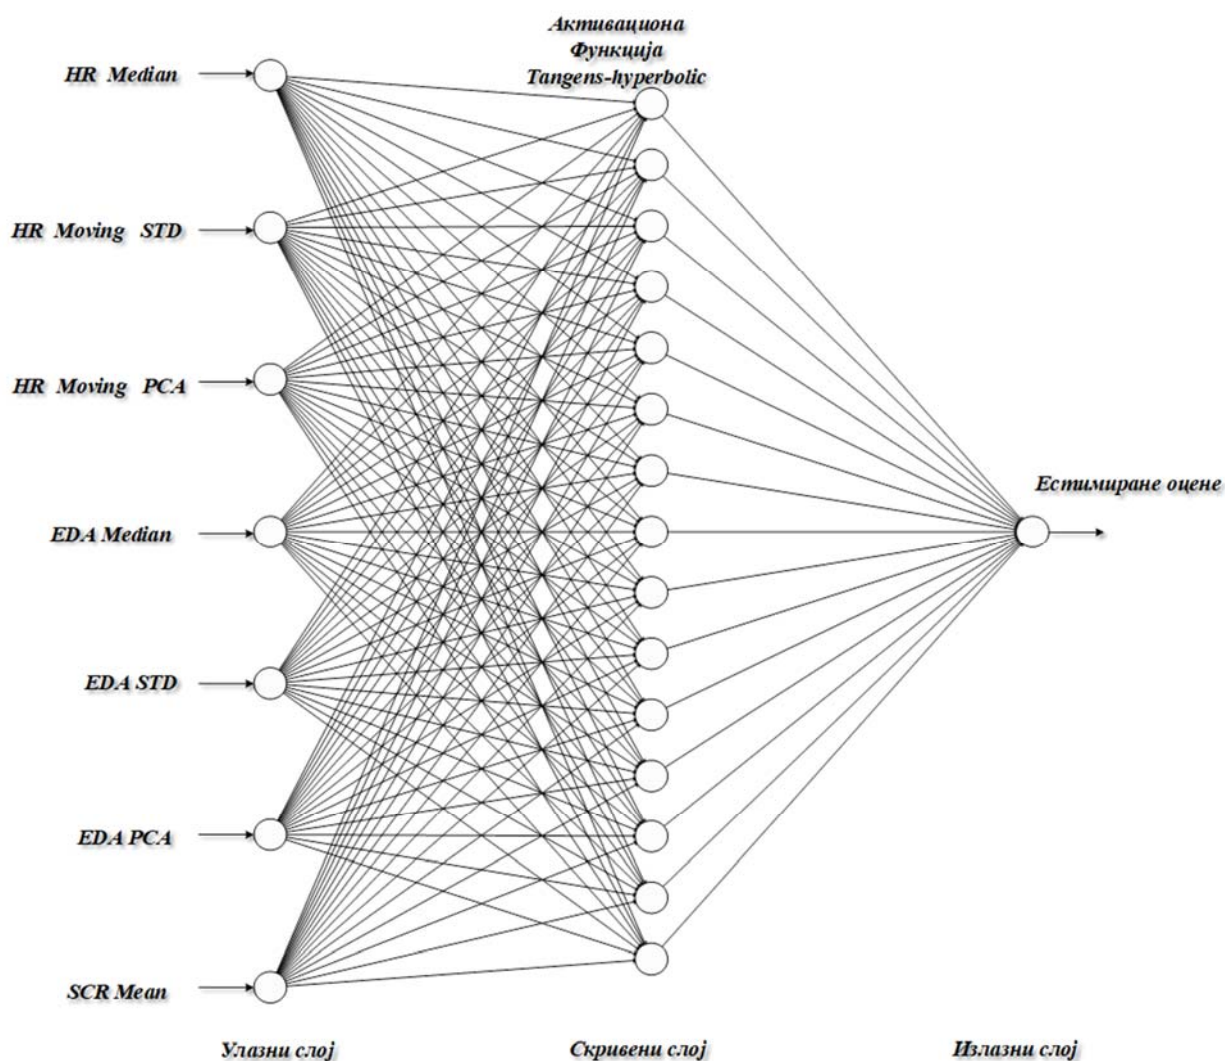
| | Чeони режањ | Потиљачни режањ | Темени режањ |
|-------------------|----------------------|------------------------|-----------------------|
| Изабрана обележја | alpha asym MEDIAN | occipital alpha MEDIAN | parietal alpha MEDIAN |
| | frontal alpha MEDIAN | occipital beta MEDIAN | parietal beta MEDIAN |
| | frontal beta MEDIAN | occipital gamma MEDIAN | parietal gamma MEDIAN |
| | frontal gamma MEDIAN | occipital theta MEDIAN | parietal theta MEDIAN |
| | frontal theta MEDIAN | | |

ТАБЕЛА 9 – ОДАБРАНА ОБЕЛЕЖЈА МОДЕЛА *EEG*

7.3.2 Поставка неуронске мреже

Да би се проценило емоционално стање учесника током гледања стереоскопских 3Д секвенци, коришћена је вештачка неуронска мрежа позната као повратни вишеслојни перцептрон (енгл. *feed-forward Multilayer Perceptron MLP*) чија је математичка поставка објашњена у секцији „Вишеслојни перцептрон“. Један од разлога што је избор на вишеслојном перцептрону лежи у једноставности постављања мреже па се због тога не уноси додатни шум на већ врло деликатном уносу. Избором једноставне мреже, жеља је била да се потврди како врло једноставна техника са минимумом рачунарских ресурса може дати значајне резултате процене доказане у [102][104][106][108].

Горе поменути повратни вишеслојни перцептрон конфигуриран је тако да на улазу садржи n улаза при чему је у случају HR/EDA модела $n = 7$, а у случају EEG модела $n = 13$ након избора обележја и оптимизације. Број неурона на скривеном слоју постављен је тако да се израчунава као $2n + 1$. Функција активације на скривеним чворовима је хиперболична функција активације тангенте - хиперболични тангенс $f(u_k) = \frac{2}{1+e^{-u_k}}$, где улаз скалира вредности између -1 и 1 применом прага. Вредност хиперболичне тангенте је центрирана нула, што олакшава задатак следећег неурона током ширења. Слика 23 приказује повратни вишеслојни перцептрон конфигурацију са одабраним функцијама HR/EDA модела као улазним обележјима, а Слика 24 конфигурацију са одабраним функцијама EEG модела као улазним обележјима.



Слика 23 MLP конфигурација са HR и EDA одабраним карактеристикама као улазом

Број подела (девет) у односу тренинга и теста изабран је на основу броја секвенци како се секвенце не би преплитале и на тај начин обезбедила могућност анализе улазног сета података у односу на тип видеа и количину оштећености. Дакле, избор овакве поставке је јер се на тај начин тест увек изводио на различитим и „непознатим“ видео секвенцама. Сваки пролаз је користио 1/9 за тестирање који представља узорке из друге видео секвенце која се не користи за тренинг.

Вектори жељених вредности излаза постављен је као излаз из субјективних оцена приликом гледања одређене секвенце. На тај начин је обезбеђена обука са надзором.

За излазни чвор изабрана је линеарна функција активирања. Резултат повратног вишеслојног перцептрона на основу поставке мреже и вектора жељених вредности је вектор процењених резултата. За упоређивање стварних субјективних резултата и процењених субјективних резултата израчунати су корен средње квадратне грешке, Пеарсонова корелација, Спепарманова корелација и стандардна девијација.

Како би се поредили реални субјективни резултати добијени помоћу оцена испитаника и процењени субјективни резултати, као и перформансе мреже вишеслојног перцептрона, након моделовања повратног вишеслојног перцептрона на исти начин, са истим бројем улаза и поделом као и свим параметрима мреже постављене су и неуронска мрежа са општом регресијом као и метод потпорних вектора. На тај начин обезбеђена је могућност упоредне анализе резултата проценитеља и одабир најтачнијег проценитеља. С обзиром да се ради о врло сличним техникама процене показало се да су разлике у резултатима мале што је детаљније обрађено у секцији „Упоредна анализа“. Малe разлике у побољшањима приликом промене технике машинског учења, доводе до закључка да се приказаним моделовањем може доћи до прецизне процене квалитета доживљаја независно од избора технике машинског учења што овом приступу даје генерализацију и доказује почетну хипотезу да се такав модел може направити.

8 Резултати и дискусија

Процењени субјективни резултати добијени као излаз из вишеслојног перцептрона, мреже са општом регресијом и методом потпорних вектора, упоређени су са стварним субјективним резултатима. Резултати упоређивања дати су кроз корен средње квадратне грешке *RMSE*, ПEARСОНОВ коефицијент корелације, СпЕАРМАНОВ коефицијент корелације и стандардну девијацију *STD*.

Како би се проверио утицај сваког обележја понаособ, број обележја је вариран као улаз у неку од техника машинског учења, те је на овај начин извршена анализа прецизности сваког модела. Процена субјективних оцена је урађена за обе скале - скалу узбуђења и скалу задовољства. У даљем тексту дати су резултати и дискусија резултата на основу упоредне анализе различитих модела у смислу броја улаза, комбинације улаза и технике машинског учења. Резултати се разматрају на следећи начин. Прво се расправља о најбољем проценитељу са HR и EDA обележјима заједно као и одвојено са само HR и само EDA одабраним обележјима као улазним подацима како би се испитао утицај две различите природе улаза на процењивач. Након тога, проучава се модел са свим EEG обележјима како би се разјаснило колико је ова врста процењивача боља или лошија. На крају се испитују појединачне улазне процене за све три врсте карактеристика.

8.1 Упоредна анализа


Након издвајања обележја, одабира и поставке технике машинског учења неопходно је испитати утицаје различитих комбинација одабраних обележја. Постављена је претпоставка да ће се модели са највећим бројем улаза показати као најпрецизнији проценитељи. Табела 10 представља модел са највећим бројем улаза за HR и EDA моделе за све три врсте техника машинског учења: вишеслојни перцептрон (у даљем тексту MLP), неуронска мрежа са општом регресијом (у даљем тексту GRNN) и метод регресије потпорним векторима (у даљем тексту SVR). Из резултата приказаних у Табели 10 може се закључити да је прецизност MLP и GRNN веома висока, те на тај начин може закључити да је за модел који користи све улазе HR и EDA, седам улаза и више него довољно да би се постигао изразито добар резултат процене. С обзиром на чињеницу да MLP и GRNN дају резултате који се веома мало разликују у појединим случајевима, у даљем тексту биће

ПОГЛАВЉЕ 8 – Резултати и дискусија

анализирани само случајеви са већим разликама у процењеним вредностима или граничним случајевима када се жели показати одређена сличност или различитост, при чему је тежиште рада на MLP проценитељима.

| Мере | Процена узбуђења употребом MLP | Процена узбуђења употребом GRNN | Процена узбуђења употребом SVR | Процена задовољства употребом MLP | Процена задовољства употребом GRNN | Процена задовољства употребом SVR |
|--------------------------------------|--------------------------------|---------------------------------|--------------------------------|-----------------------------------|------------------------------------|-----------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.050 | 0.116 | 2.437 | 0.024 | 0.142 | 2.267 |
| Пеарсон корелација (Pearson) | 0.999 | 0.998 | 0.256 | 0.999 | 0.993 | 0.267 |
| Сpearман корелација (Spearman) | 0.964 | 0.963 | 0.289 | 0.959 | 0.957 | 0.299 |
| Стандардна девијација (STD) | 0.036 | 0.087 | 1.294 | 0.026 | 0.277 | 0.916 |

ТАБЕЛА 10 MLP, GRNN и SVR ПРОЦЕНИТЕЉИ СА СВИМ HR И EDA УЛАЗИМА



Слика 25 – Графички приказ Табеле 10

Даље, на основу резултата приказаних у Табели 10 (Слика 25) може се видети да је корен средње квадратне грешке нешто бољи за резултате процењене помоћу MLP-а од резултата које користе општу регресиону неуронску мрежу. Коефицијенти корелације Пеарсона и Сpearмана су готово једнаки. У случају методе потпорних вектора у регресији резултати нису задовољавајући. Модел заснован на SVR методи има најлошији RMSE и коефицијенти корелације су знатно нижи, што ову технику машинског учења дисквалификује из даље упоредне анализе и дискусије у потрази за моделом најбољег проценитеља.

ПОГЛАВЉЕ 8 – Резултати и дискусија

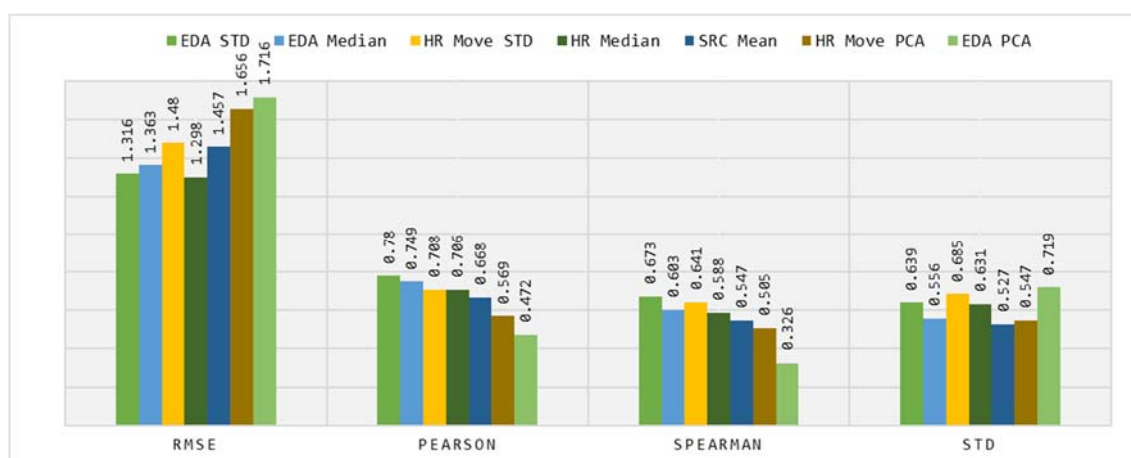
Улазни подаци за први предложени проценитељ су одабрана обележја из HR и EDA модела заједно, те будући да је RMSE готово близу нуле и за узбуђење и за скалу задовољства, може се закључити да овај проценитељ има тачну процену људског субјективног оцењивања. Такође, Пеарсон и Спearман коефицијенти корелације су готово једнаки 1 и за узбуђење и за задовољство, што значи да је тачност модела 99% те је генерална хипотеза о не персонализованом моделу потврђена. Ова врло висока тачност долази из различитих типова психо-физиолошких сигнала HR и EDA и њихове природе, те се њиховом комбинованом употребом добијају најбоље перформансе.

Да би се испитало која психо-физиолошка мера више одговара уносу у MLP, број улазних обележја је вариран и анализирани су различити модели са HR и EDA обележјима понаособ. Испитивани су модели са само једним обележјем, комбинацијом два, три и са свим HR обележјима, као и са свим EDA обележјима. Приказани су и дискутовани само најбољи проценитељи.

Модели са само једним улазним параметром су сигурно најслабији, што је приказано у Табелама 11 и 12.

| Процена узбуђења - Мере | EDA STD | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA |
|--------------------------------------|---------|------------|-------------|-----------|----------|-------------|---------|
| Корен средње квадратне грешке (RMSE) | 1.316 | 1.363 | 1.48 | 1.298 | 1.457 | 1.656 | 1.716 |
| Пеарсон корелација (Pearson) | 0.780 | 0.749 | 0.708 | 0.706 | 0.668 | 0.569 | 0.472 |
| Спearман корелација (Spearman) | 0.673 | 0.603 | 0.641 | 0.588 | 0.547 | 0.505 | 0.326 |
| Стандардна девијација (STD) | 0.639 | 0.556 | 0.685 | 0.631 | 0.527 | 0.547 | 0.719 |

ТАБЕЛА 11 ПРОЦЕНИТЕЉ УЗБУЂЕЊА MLP СА ПОЈЕДИНАЧНИМ УЛАЗНИМ ОБЕЛЕЖЈИМА



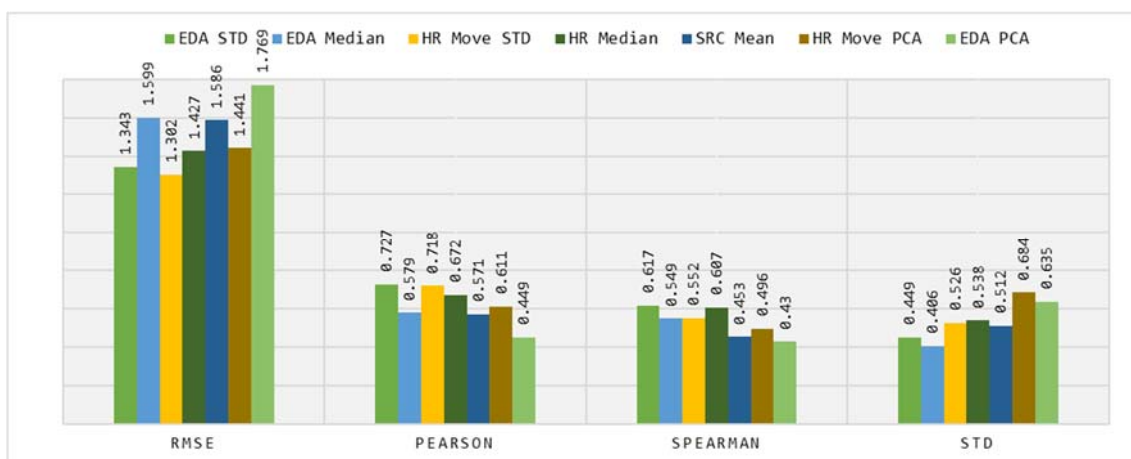
Слика 26– Графички приказ Табеле 11

ПОГЛАВЉЕ 8 – Резултати и дискусија

На основу вредности корена средње квадратне грешке и корелационих коефицијената из Табела 11 и 12, јасно се види да модел са само једним обележјем EDA PCA као улазом у MLP има најлошије резултате. Модел са само једним обележјем EDA STD има најбоље перформансе међу свим осталим улазним моделима.

| Процена задовољства – Мере | EDA STD | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA |
|--------------------------------------|---------|------------|-------------|-----------|----------|-------------|---------|
| Корен средње квадратне грешке (RMSE) | 1.343 | 1.599 | 1.302 | 1.427 | 1.586 | 1.441 | 1.769 |
| Пearсон корелација (Pearson) | 0.727 | 0.579 | 0.718 | 0.672 | 0.571 | 0.611 | 0.449 |
| Сpearман корелација (Spearman) | 0.617 | 0.549 | 0.552 | 0.607 | 0.453 | 0.496 | 0.430 |
| Стандардна девијација (STD) | 0.449 | 0.406 | 0.526 | 0.538 | 0.512 | 0.684 | 0.635 |

ТАБЕЛА 12 ПРОЦЕНТЕЉ ЗАДОВОЉСТВА MLP СА ПОЈЕДИНАЧНИМ УЛАЗНИМ ОБЕЛЕЖЈИМА



Слика 27– Графички приказ Табеле 12


| Мере | Процена узбуђења употребом MLP | Процена узбуђења употребом GRNN | Процена задовољства употребом MLP | Процена задовољства употребом GRNN |
|--------------------------------------|--------------------------------|---------------------------------|-----------------------------------|------------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.408 | 0.542 | 0.561 | 0.622 |
| Пearсон корелација (Pearson) | 0.966 | 0.916 | 0.909 | 0.944 |
| Сpearман корелација (Spearman) | 0.935 | 0.919 | 0.871 | 0.902 |
| Стандардна девијација (STD) | 0.573 | 0.387 | 0.697 | 0.543 |

ТАБЕЛА 13 ПРОЦЕНТЕЉИ MLP И GRNN СА СВИМ УЛАЗИМА HR ОБЕЛЕЖЈИМА

Ако се упореде модели са свим обележјима HR-а и свим EDA обележјима као улазом у MLP и GRNN, закључак је да је EDA модел тачнији јер има више улаза, али и због добро познате чињенице да EDA има мање варијација у понашању од HR-а, па су модели који

ПОГЛАВЉЕ 8 – Резултати и дискусија

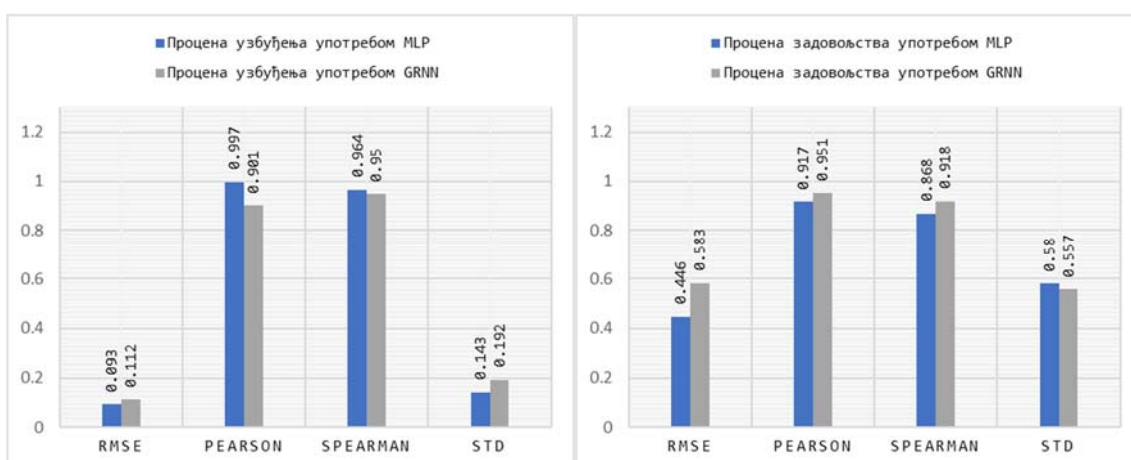
користе EDA податке стабилнији и прецизнији. Може се уочити да је за процену узбуђења модел који користи MLP као проценитеља бољи у процени у случају узбуђења, док је GRNN незнатно бољи у процени задовољства уколико се посматра корелациони коефицијент али и да је корен средње квадратне грешке већи. Табеле 13 и 14 резимирају ове моделе.



Слика 28 – Графички приказ Табеле 13

| Мере | Процена узбуђења употребом MLP | Процена узбуђења употребом GRNN | Процена задовољства употребом MLP | Процена задовољства употребом GRNN |
|--------------------------------------|--------------------------------|---------------------------------|-----------------------------------|------------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.093 | 0.112 | 0.446 | 0.583 |
| Пеарсон корелација (Pearson) | 0.997 | 0.901 | 0.917 | 0.951 |
| Спеарман корелација (Spearman) | 0.964 | 0.950 | 0.868 | 0.918 |
| Стандардна девијација (STD) | 0.143 | 0.192 | 0.580 | 0.557 |

ТАБЕЛА 14 ПРОЦЕНИТЕЉ MLP И GRNN СА СВИМ УЛАЗИМА EDA ОБЕЛЕЖИЈА

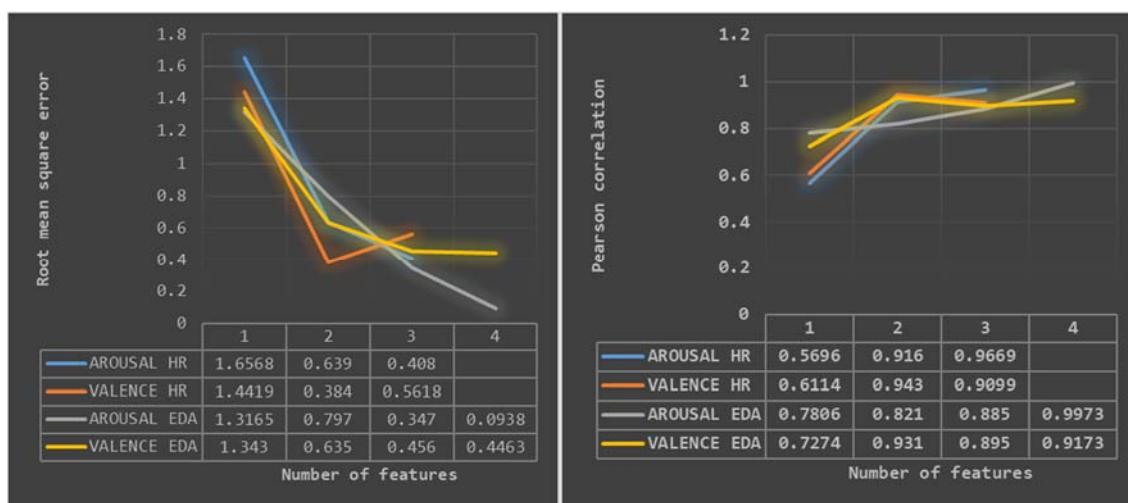


Слика 29 – Графички приказ Табеле 14

ПОГЛАВЉЕ 8 – Резултати и дискусија

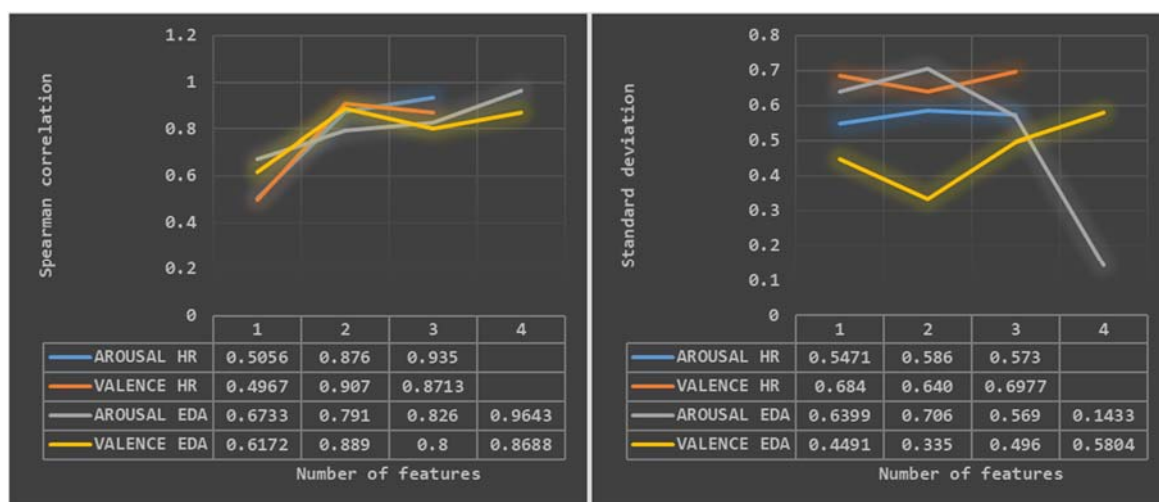
Резултати добијени за моделе са комбиновањем броја само HR и само EDA улазним обележјима приказани су на следећим сликама. Просечна квадратна грешка модела за све HR улазе и све EDA улазе за узбуђење и задовољство представљена је на Слици 30.

На сликама које графички представљају резултате, може се јасно видети да је корен средње квадратне грешке мањи, а корелација већа када се дода више обележја на улазу неуронске мреже. Само је један изузетак примећен за процену задовољства на основу обележја HR (наранџаста линија), јер модел има већи корен средње квадрате грешке када се дода последње обележје (HR Move STD).



Слика 30 (лево) Корен средње квадратне вредности за све HR улазе и све EDA улазе за скалу узбуђења и задовољства.

Слика 31 (десно) Пеарсон корелациони коефицијент за HR улазе и све EDA улазе за скалу узбуђења и задовољства



Слика 32 (лево) Спearман корелациони коефицијент за HR улазе и све EDA улазе за скалу узбуђења и задовољства

Слика 33 (десно) Стандардна девијација за HR улазе и све EDA улазе за скалу узбуђења и задовољства

ПОГЛАВЉЕ 8 – Резултати и дискусија

То је зато што HR Move STD има најлошију корелацију између све три карактеристике у моделу HR-a, те не доприноси квалитету моделу. Пеарсонова корелација на слици 31, Спелманова корелација на слици 32 и стандардна девијација на слици 33 на исти начин потврђују претходну тврдњу.

Испробане су и варијације модела када се користе само два обележја. У табели 15 дати су резултати комбиновањем два обележја у случају модела када се процењивало узбуђење, а у табели 16 дат је пролаз резултата за скалу задовољства.

| Узбуђење | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA |
|-------------|--------------------------------------|-------------|-----------|----------|-------------|---------|------------------------------|-------------|-----------|----------|-------------|---------|
| | Корен средње квадратне грешке (RMSE) | | | | | | Пеарсон корелација (Pearson) | | | | | |
| EDA STD | 0.797 | 0.462 | 0.716 | 0.683 | 0.393 | 0.909 | 0.821 | 0.945 | 0.864 | 0.867 | 0.950 | 0.822 |
| EDA Median | * | 0.572 | 0.332 | 0.734 | 0.469 | 1.128 | * | 0.939 | 0.977 | 0.868 | 0.956 | 0.793 |
| HR Move STD | * | * | 0.707 | 0.669 | 1.351 | 1.229 | * | * | 0.897 | 0.890 | 0.737 | 0.777 |
| HR Median | * | * | * | 0.543 | 0.639 | 0.738 | * | * | * | 0.914 | 0.916 | 0.919 |
| SRC Mean | * | * | * | * | 0.697 | 0.785 | * | * | * | * | 0.900 | 0.877 |
| HR Move PCA | * | * | * | * | * | 1.028 | * | * | * | * | * | 0.816 |
| | Спелман корелација (Spearman) | | | | | | Стандардна девијација (STD) | | | | | |
| EDA STD | 0.791 | 0.906 | 0.824 | 0.803 | 0.914 | 0.751 | 0.706 | 0.658 | 0.646 | 0.622 | 0.791 | 0.663 |
| EDA Median | * | 0.892 | 0.951 | 0.852 | 0.925 | 0.754 | * | 0.639 | 0.300 | 0.476 | 0.477 | 0.552 |
| HR Move STD | * | * | 0.869 | 0.858 | 0.718 | 0.698 | * | * | 0.987 | 0.630 | 0.849 | 0.906 |
| HR Median | * | * | * | 0.872 | 0.876 | 0.861 | * | * | * | 0.588 | 0.586 | 0.397 |
| SRC Mean | * | * | * | * | 0.862 | 0.846 | * | * | * | * | 0.672 | 0.456 |
| HR Move PCA | * | * | * | * | * | 0.815 | * | * | * | * | * | 0.970 |

ТАБЕЛА 15 ПРОЦЕНИТЕЉ УЗБУЂЕЊА КОМБИНАЦИЈА СА ДВА HR И EDA УЛАЗА

У случају узбуђења најбољи резултати добијени су комбинацијом *HR Median* и *EDA Median*, а најлошије *HR Move PCA* и *HR Move STD* те се на основу резултата и комбиновањем броја улаза, анализом потпуног простора улазних обележја, може проценити која је комбинација улазних обележја најбоља и на тај начин успоставити оптималан број улаза.

Табела 16 на исти начин сумира резултате комбиновањем два обележја за скалу задовољства, а резултати показују да је најбољи резултат добијен у комбинацији *HR Median* и *EDA STD*, а најлошији *HR Move PCA* и *HR Move STD*. У ова случаја може се приметити да је *HR Move PCA* и *HR Move STD* најлошија комбинација обележја у случају два улаза.

ПОГЛАВЉЕ 8 – Резултати и дискусија

| Задовољство | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA | EDA Median | HR Move STD | HR Median | SRC Mean | HR Move PCA | EDA PCA |
|-------------|--------------------------------------|-------------|-----------|----------|-------------|---------|------------------------------|-------------|-----------|----------|-------------|---------|
| | Корен средње квадратне грешке (RMSE) | | | | | | Пearсон корелација (Pearson) | | | | | |
| EDA STD | 0.635 | 0.465 | 0.274 | 0.645 | 0.511 | 0.965 | 0.931 | 0.938 | 0.979 | 0.882 | 0.937 | 0.854 |
| EDA Median | * | 0.635 | 0.519 | 0.778 | 0.339 | 0.838 | * | 0.916 | 0.924 | 0.858 | 0.970 | 0.866 |
| HR Move STD | * | * | 0.346 | 0.541 | 1.362 | 0.802 | * | * | 0.952 | 0.932 | 0.686 | 0.864 |
| HR Median | * | * | * | 0.727 | 0.384 | 1.160 | * | * | * | 0.863 | 0.943 | 0.760 |
| SRC Mean | * | * | * | * | 0.535 | 0.976 | * | * | * | * | 0.922 | 0.813 |
| HR Move PCA | * | * | * | * | * | 0.869 | * | * | * | * | * | 0.844 |
| | Сpearман корелација (Spearman) | | | | | | Стандардна девијација (STD) | | | | | |
| EDA STD | 0.889 | 0.894 | 0.942 | 0.839 | 0.882 | 0.777 | 0.335 | 0.417 | 0.367 | 0.665 | 0.513 | 0.442 |
| EDA Median | * | 0.879 | 0.888 | 0.778 | 0.931 | 0.820 | * | 0.600 | 0.669 | 0.585 | 0.364 | 0.528 |
| HR Move STD | * | * | 0.897 | 0.901 | 0.622 | 0.796 | * | * | 0.421 | 0.525 | 0.706 | 0.756 |
| HR Median | * | * | * | 0.830 | 0.907 | 0.693 | * | * | * | 0.855 | 0.640 | 0.795 |
| SRC Mean | * | * | * | * | 0.899 | 0.762 | * | * | * | * | 0.543 | 0.557 |
| HR Move PCA | * | * | * | * | * | 0.769 | * | * | * | * | * | 0.732 |

ТАБЕЛА 16 ПРОЦЕНИТЕЉ ЗАДОВОЉСТВА КОМБИНАЦИЈА СА ДВА HR И EDA УЛАЗА

Сличан приступ је примењен на моделима који имају EEG карактеристике као улазе. Модел са свим EEG обележјима, као улазом у MLP, дат у Табели 17, има најбоље перформансе и најтачнији је јер има 13 улаза. Такође се испитују три различита модела у зависности од региона мозга.


| Мере | Процена узбуђења употребом MLP | Процена задовољства употребом MLP |
|--------------------------------------|--------------------------------|-----------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.032 | 0.029 |
| Пearсон корелација (Pearson) | 0.999 | 0.999 |
| Сpearман корелација (Spearman) | 0.970 | 0.975 |
| Стандардна девијација (STD) | 0.033 | 0.021 |

ТАБЕЛА 17 ПРОЦЕНИТЕЉ СА СВИМ EEG ОБЕЛЕЖИМА КАО УЛАЗИМА

| Мере | Процена узбуђења употребом MLP | Процена задовољства употребом MLP |
|--------------------------------------|--------------------------------|-----------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.198 | 0.068 |
| Пearсон корелација (Pearson) | 0.960 | 0.998 |
| Сpearман корелација (Spearman) | 0.943 | 0.975 |
| Стандардна девијација (STD) | 0.466 | 0.079 |

ТАБЕЛА 18 ПРОЦЕНИТЕЉ СА СВИМ EEG ОБЕЛЕЖИМА У ПОТИЉАЧНОМ И ЧЕОНОМ РЕЖЉУ КАО УЛАЗИМА

ПОГЛАВЉЕ 8 – Резултати и дискусија



Слик 34 - Графички приказ Табела 17 (лево) и 18 (десно)

Резултати дати у Табели 18, Табели 19 и Табели 20 одговарају резултатима када су подаци распоређени тако да користе само улазе у MLP из чеоног, потиљачног и теменог режња мозга. На основу резултата потврђена је претходно поменути тврдња да је потиљачни режањ најрелевантније подручје мозга у сврху овог истраживања.

| Мере | Процена узбуђења употребом MLP | Процена задовољства употребом MLP |
|--------------------------------------|--------------------------------|-----------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.052 | 0.095 |
| Пеарсон корелација (Pearson) | 0.999 | 0.990 |
| Спеарман корелација (Spearman) | 0.970 | 0.957 |
| Стандардна девијација (STD) | 0.044 | 0.202 |


ТАБЕЛА 19 ПРОЦЕНИТЕЉ СА СВИМ EEG ОБЕЛЕЖИМА У ПОТИЉАЧНОМ РЕЖЊУ КАО УЛАЗИМА ЗА СВА МЕДИЈАНА ОБЕЛЕЖЈА

| Мере | Процена узбуђења употребом MLP | Процена задовољства употребом MLP |
|--------------------------------------|--------------------------------|-----------------------------------|
| Корен средње квадратне грешке (RMSE) | 0.1767 | 0.1562 |
| Пеарсон корелација (Pearson) | 0.9619 | 0.9736 |
| Спеарман корелација (Spearman) | 0.9274 | 0.9406 |
| Стандардна девијација (STD) | 0.4009 | 0.3467 |

ТАБЕЛА 20 ПРОЦЕНИТЕЉ СА СВИМ EEG ОБЕЛЕЖИМА У ТЕМЕНОМ РЕЖЊУ КАО УЛАЗИМА ЗА СВА МЕДИЈАНА ОБЕЛЕЖЈА

То значи да се све функције повезане са потиљачном регијом морају узети у обзир приликом процене емоционалног стања човека док гледате 3Д видео.

ПОГЛАВЉЕ 8 – Резултати и дискусија



Слик 35 - Графички приказ Табела 19 (лево) и 20 (десно)


Модели са само једним обележјем испитују се за EEG сигнале на исти начин као у случају HR / EDA модела. Табела 21 сумира моделе са само једним улазом. Такође, се истражују модели са различитим можданим таласима (Табела 1) у погледу можданих таласа и људског емоционалног стања. Поред тога, утицај различитих улазних обележја на студију процењивача, утицај визуелне нелагодности на емоционална стања представљен је на сликама 36, 37 и 38. Хипотеза да на емоционално стање (узбуђење) утиче повећањем изобличења видео секвенце, се може потврдити на графицима, јер се у сва три примера готово савршено подударају стварни и процењени резултати, и оцена расте са порастом узбуђења. Најмање тачна процена је дата за тип видео секвенци са средњим узбуђењем. На основу слика 36, 37 и 38 може се закључити да је корен средње квадратне грешке већи у случају скале узбуђења него у случају задовољства.

| Мере | alpha asym MEDIAN | frontal alpha MEDIAN | frontal beta MEDIAN | frontal gamma MEDIAN | frontal theta MEDIAN | occipital alpha MEDIAN | occipital beta MEDIAN | occipital gamma MEDIAN | occipital theta MEDIAN | parietal alpha MEDIAN | parietal beta MEDIAN | parietal gamma MEDIAN | parietal theta MEDIAN |
|-----------------------|----------------------|----------------------------|---------------------------|----------------------------|----------------------------|------------------------------|-----------------------------|------------------------------|------------------------------|-----------------------------|----------------------------|-----------------------------|-----------------------------|
| 1) Узбуђење | | | | | | | | | | | | | |
| RMSE | 1.581 | 1.716 | 1.688 | 1.682 | 1.613 | 1.708 | 1.512 | 1.671 | 1.571 | 1.747 | 1.678 | 1.409 | 1.432 |
| Пearсон | 0.555 | 0.474 | 0.552 | 0.555 | 0.590 | 0.602 | 0.661 | 0.561 | 0.602 | 0.449 | 0.472 | 0.688 | 0.702 |
| Сpearман | 0.519 | 0.404 | 0.452 | 0.474 | 0.476 | 0.443 | 0.575 | 0.451 | 0.467 | 0.238 | 0.445 | 0.519 | 0.590 |
| STD | 0.682 | 0.338 | 0.639 | 0.372 | 0.599 | 0.576 | 0.241 | 0.372 | 0.614 | 0.638 | 0.531 | 0.577 | 0.524 |
| 2) Задовољство | | | | | | | | | | | | | |
| RMSE | 1.789 | 1.612 | 1.558 | 1.402 | 1.507 | 1.544 | 1.617 | 1.756 | 1.530 | 1.563 | 1.732 | 1.489 | 1.543 |
| Пearсон | 0.417 | 0.530 | 0.525 | 0.658 | 0.555 | 0.624 | 0.548 | 0.454 | 0.592 | 0.603 | 0.460 | 0.611 | 0.604 |
| Сpearман | 0.309 | 0.427 | 0.464 | 0.597 | 0.455 | 0.561 | 0.473 | 0.306 | 0.549 | 0.438 | 0.371 | 0.543 | 0.561 |
| STD | 0.520 | 0.592 | 0.475 | 0.401 | 0.431 | 0.391 | 0.451 | 0.660 | 0.453 | 0.446 | 0.669 | 0.483 | 0.341 |


ТАБЕЛА 21 ПРОЦЕНИТЕЉ СА ПОЈЕДИНАЧНИМ ОБЕЛЕЖЈИМА (EEG МЕДИЈАНА) ЗА 1) УЗБУЂЕЊЕ И 2) ЗАДОВОЉСТВО

ПОГЛАВЉЕ 8 – Резултати и дискусија

Модел са само једним улазом у неуронску мрежу најбољи је када се као улаз искористи *parietal theta MEDIAN* (чеони) у случају узбуђења, и *frontal gamma MEDIAN* (темени) у случају задовољства.



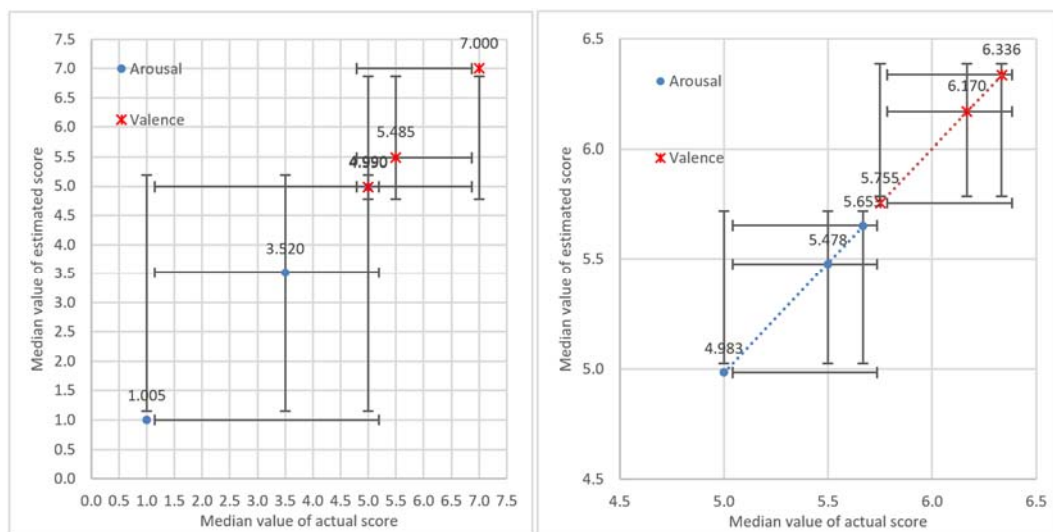
Слика 36 Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) мирног видеа



Слика 37 Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) средње умереног видеа

На Сликама 36, 37 и 38 (лево) може се видети утицај шума на емоционално стање корисника у случају мирног видеа. Може се приметити да се узбуђење драстично повећава са повећањем оштећења што је приказано великом разликом оцена (1.010-6.000; 1.445-4.980; 1.005-4.990), при чему је стандардна девијација велика и оцене варирају од субјекта

до субјекта. Слично се може уочити и у случају средње умереног (Слика 37) и веома узбудљивог видеа (Слика 38).



Слика 38 - Утицај шума (лево) и типа видео секвенце (десно) на емоционално стање узбуђење (плаво) и задовољство (црвено) веома узбудљивог видеа

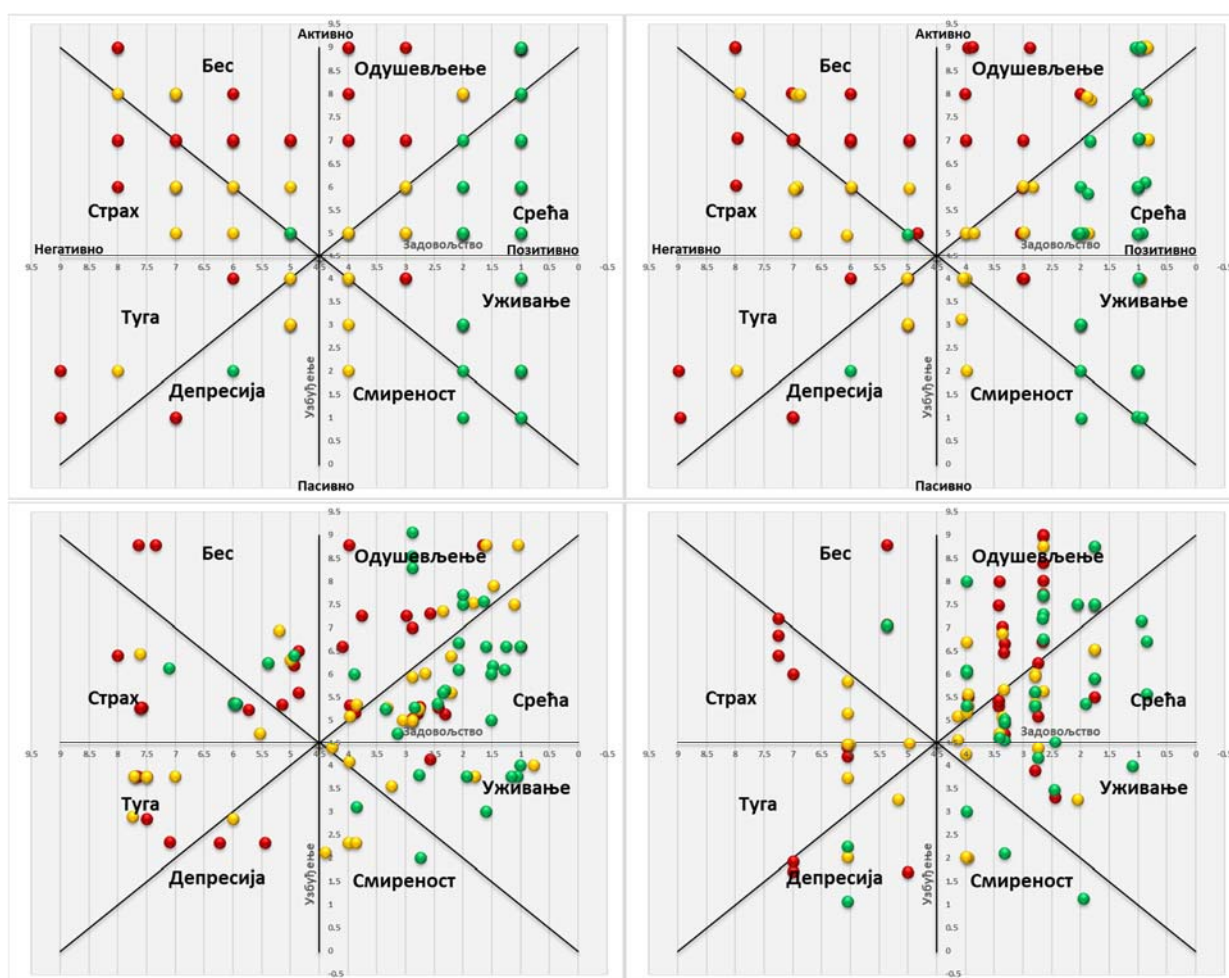
С обзиром да се исто понашање може уочити у сва три типа видео записа може се закључити да људи реагују на исти начин независно од типа садржаја када је у питању узбуђење. Ако се упоредно резимирају типови видеа, на Сликама 36, 37 и 38 (десно), оцена узбуђења је већа за веома узбудљив видео, али је и стандардна девијација већа, те се може закључити да је ниво узбуђења субјективан што може увести додатне проблеме приликом генерализације модела. Са повећањем узбуђења у видео секвенцама расте и стандардна девијација, тачније различитост у оцењивању код појединаца - најлакше је проценити миран тип видеа.

Са друге стране задовољство нема драстичне варијације код мирног и умерено узбудљивог садржаја приликом уношења већег шума јер оцене варирају у опсегу од 5 до 6 што је на скали од 9 оцена мала разлика. Међутим, код веома узбудљивог садржаја уношењем већег шума долази до већег опсега оцене (4.9 - 7). Интересантан је и резултат да се и задовољство повећава са уношењем узбуђења у 3Д видео запис.

На крају, када се оцене задовољства и узбуђења графички прикажу у дводимензионалном моделу емоционалних стања као што је то приказано на Слици 39 може се веома јасно видети у каквом стању се налазио корисник приликом излагања одређеном видео запису. Слика 39а) (горе лево) приказује однос оцена забележених упитником при

ПОГЛАВЉЕ 8 – Резултати и дискусија

чему се овај однос користи као референтни модел емоционалних стања за дату студију. Са референтног модела може се уочити да је распоред оцена равномерна у свим квадрантима, те да се јављају готово равномерно све емоције, што је очекивано, ако се узме у обзир да је база и конструисана како би обухватила што већи спектар емоција. Маркери обележени зеленом бојом означавају оцене за видео типа 1 тачније видео мирних сцена, док жута и црвена представљају оцене за видео типа 2 (умерених сцена) и типа 3 (хорор сцена), респективно. Јасно се може уочити да се зелене тачке гомилају у квадрантима који означавају позитиван део скале задовољства, а да се жуте расипају готово у свим квадрантима. Расипање жутих тачака може се објаснити чињеницом да се најтеже могу оценити неутралне сцене или умерено акционе сцене јер нема екстремних промена психофизиолошких параметара.



Слика 39 – а) Оцене забележе упитником (горе лево); б) Процењена оцена најбољег проценитеља HR и EDA модела (горе десно); в) Процењена оцена просечног проценитеља за обележје HR Median (доле лево); г) Процењена оцена најлошијег проценитеља за обележје EDA PCA (доле десно)

Црвене тачке распоређене су очекивано у квандранима који показују бес, страх, тугу и депресију, дакле негативну скалу задовољства што је и очекивано за хорор садржај. Међутим, појављују се и у простору задовољства, те се на тај начин може установити да 3Д екстремни садржај изазива спектар активних негативних, али и активних позитивних осећања – узбуђење.

Даље, на Слици 39б) (горе десно) приказана је расподела оцена за најбољи проценитељ из HR и EDA модела. Слика 39б) (горе десно) демонстрира колико је прецизно модел проценио тренутно стање учесника уз помоћ психо-физиолошких сигнала снимљених сензорима. Перформансе модела дате су у претходно разматраној Табели 10. Пасивна стања скале узбуђења, било она негативна или позитивна у смислу задовољства процењена су са 100% тачношћу, док се код активних стања посебно позитивних, као што су одушевљење и срећа могу наћи веома мала одступања. Међутим, уколико се даље анализирају моделовани проценитељи, Слика 39в) доле лево и десно, проценитељ са мањом тачношћу са једним улазом *HR Median* (≈ 0.7 Пеарсонов коефицијент) и најлошији проценитељ са једним улазом EDA PCA (≈ 0.4 Пеарсонов коефицијент) респективно, може се уочити да се оцена гомила у квадрантима са активним стањима као, а посебно позитивним. То је зато што су сцене које изазивају екстремне емоције као што су велика срећа или велики страх, такве да утичу на драстичан скок у психо-физиолошким сигнаlima те се промена лакше може и уочити и на тај начин проценитељи боље процењују него у случају стања пасивно-негативног простора модела емоционалних стања. Иако непрецизни, модели са мањим бројем улаза, могу бити корисни у системима где је неопходно детектовати негативне емоције или екстремно активно стање. Такви сценарији би могли бити екстремна узбуђеност приликом хорор сцена у случају корисника са хроничним болестима или страх од дешавања у току вожње који може узроковати непромишљене реакције код неискусних или нервозних возача итд.

Потребно је напоменути да није могуће утврдити да ли се мешање боја у моделима 39в) и 39г) дешава због тога што се одређене емоције могу теже или лакше проценити због своје природе или због тога што је на емоције утицало оштећење 3Д видео садржаја. Претпоставка је да би се база без дисторзије боље показала и да би прецизност била већа. Између осталог то је један од разлога због чега даљи рад на овом истраживању укључује испитивање модела на другим базама.

9 Закључак

Основни циљ дисертације, био је моделовање утицаја 3Д видеа на квалитет доживљаја, те с тим у вези и проценитеља емотивног стања крајњег корисника повезаног са варијацијама квалитета доживљаја 3Д видео записа, ослањајући се на директно мерење психо-физиолошких сигнала. Потреба за овим истраживањем заснива се на све већој употреби паметних система за препоруку садржаја и процену емоционалног стања, жеље корисника и квалитета доживљаја, на основу визуелних стимулуса, као и процењивање догађаја у стварним условима.

Идеја у основи предложеног приступа је истражити како се сирови подаци прикупљени од сензора који мере рад срца, електро-дермалну активност и активност мозга могу уградити у такве системе. Рад предлаже механизме машинског учења, вештачке неуронске мреже као проценитеље на основу психо-физиолошких параметара измерених у реалном времену током гледања различитих типова 3Д видео садржаја. Даље, истраживање даје увид у различите статистичке моделе који се могу користити у припреми психо-физиолошких података за употребу у анализи података (енгл. *Data mining*).

На основу резултата приказаних у раду може се закључити да се HR, EDA и EEG сигнали могу успешно применити и користити за процену човековог емоционалног стања уз помоћ вештачких неуронских мрежа за употребу у системима у реалном времену уграђеним у ТВ системе, здравство и *Infotainment*. С обзиром на то да је испитано неколико модела и више променљивих, на основу резултата може се закључити да су модели са више улаза тачнији. Методологија примењена у раду показала је да су EEG сигнали најбољи улаз за употребу у вештачким неуронским мрежама. Такође, резултати показују да HR и EDA више предвиђају стања узбуђености, а EEG ефикаснији показатељ задовољства. Такође, је показано да су карактеристике потиљачног дела мозга довољне за пружање врло тачних процена које се могу оптимизовати подешавањем броја електрода. Коначно, MLP се показао као најприкладнији начин за моделирање процењивача на овој врсти података у односу на друге испитане технике машинског учења. Међутим, неопходно је споменути да се у овом раду нису испитале све могућности SVR модела, тачније није употребљена детаљна анализа варирањем параметара као што је то урађено у случају неуронских мрежа. Из тог разлога, очекиван је даљи рад на испитивању могућности SVR модела као и других техника машинског учења.

Једно ограничење предложеног приступа је да су подаци прикупљени у лабораторијском окружењу, док би подаци прикупљени у „стварном свету“ могли бити зашумљенији (нпр. кретање дужних учесника). То сугерише да би тачност резултата могла бити нижа када се појединци крећу. Још једно ограничење је да би друге врсте техничких изобличења, осим употребљеног *Gaussian blur*, могле да произведу различите нивое визуелне нелагодности и већи утицај на промене емоционалног стања. Међу ограничењима постоји и чињеница да је испитивање усредсређено само на *Gaussian* изобличења као узрок визуелне неугодности, јер је оригинални скуп података добијен у таквом стању те се нису истражили други узроци визуелне нелагодности типично повезане са 3Д садржајем, као што су вертикално/ротационо неусклађеност, неусклађеност боје/осветљености, неусклађеност фокуса/вергенције итд. Будућа истраживања треба да прошире резултате узимајући у обзир и ове аспекте 3Д материјала.

С обзиром на чињеницу да су подаци о HR, EDA и EEG психо-физиолошким сигнаlima пружили одличне резултате са високом тачношћу за процену емоционалних стања током гледања 3Д садржаја, следећи кораци у истраживању били би моделовање сличних проценитеља, али у стварној ситуацији. Будући да процена емоционалног стања током гледања неке мултимедије може да помогне многим ТВ пружаоцима услуга да препоруче садржај на основу класификације емоција, те се будућа истраживања могу очекивати у том смеру.

Узимајући у обзир успешност техника машинског учења могле би се испитати и перформансе других доступних техника попут дубоког учења или расплинуте логике (енг. *fuzzy logic*), али и других база употребом исте методологије. На крају, стандардизација података потребних „системима оријентисаним на емоције“ има потенцијал да подстакне развој ове области зато што а) подаци који су обележени на стандардизован начин могу се лакше размењивати између система, чиме се поједностављује тржиште за базе психо-физиолошких података у сврху процене емоционалног стања или сличну употребу б) стандардизација може допринети се пружаоцима услуга система за обраду психо-физиолошких података, нпр. веб услуга за препознавање емоција из текста, говора или мултимодалног уноса.

На крају, могућности примене датог истраживања су многобројне. Методологија се може применити како у случају препоруке садржаја у ТВ индустрији, тако и у аутомобилској индустрији за праћење пажње возача, детектовање негативних емоција итд. С обзиром да се показало да се на малом скупу обележја, употребом малих сензора који се

могу монтирати на волану аутомобила, за детекцију само електро-дрмалне активности или активности срца може доћи до прецизних процена, могућности у аутомобилској индустрији су неограничене. Осим поменутих индустрија, интересантна је примена у случају виртуелне стварности или праћена емоција приликом употребе видео игара. Осим виртуелне стварности или видео игара, интересантна је употреба у случају било ког типа онлајн сервиса за детектовање задовољства или другог одговора корисника на емитовани садржај.

10 Радови које претходе докторској дисертацији

У наставку овог поглавља дата је детаљна листа радова, са кратким описом, који су у директној повезаности са истраживањем и претходе докторској дисертацији.

Рад у истакнутом међународном часопису (M22)

- [1] 2020 Ђорђевић (Слободан) Драгана, Miguel Barreda-Ángeles, Patrick Le Callet, Кукољ (Дане) Драган: *Modelling Effects of S3D Visual Discomfort in Human Emotional State Using Data Mining Techniques*, ISSN 1380-7501, Springer - Multimedia Tools and Applications, 1-27

кратак опис садржине:

Идеја је да се направи процењивач емоционалног стања и квалитета доживљаја стереоскопског 3Д видеа на основу директних мерења људских параметара без субјективне процене. Намера је показати да се поуздано процењивање емоционалних стања повезаних са стереоскопским видео садржајем може постићи без потребе за персонализацијом модела процене. Ови неперсонализовани модели могу се добити само детаљном анализом различитих врста видео записа у смислу узбуђења и задовољства. Због природе стереоскопског 3Д видеа који у многим случајевима доноси нелагоду корисницима, такође је испитно понашање модела засновано на додатном изобличењу у видео секвенци. Хипотеза је да ће људи бити несрећнији ако се појача дисторзија, тј. визуелна нелагода.

Методологија описана у раду испитује различите технике екстракције обележја и селекцију карактеристика психо-физиолошких података, које се не користе у претходно објављеним радовима као улазних података за процене емоционалног стања вештачке неуронске мреже. Један од новитета који овај рад доноси је покушај израде општег модела процене емоционалног стања. Овај рад разрађује различите моделе анализирајући утицај различитих видео садржаја, пратећи параметре прикупљене за ECG, EDA и EEG, који нису заједно испитивани у претходно објављеним радовима. Истраживање је фокусирано на

проналажење компромиса између броја улазних параметара и природе улаза у односу на грешку процене. Упоредна анализа дизајнирања модела је централни део истраживања

Саопштење са међународног скупа штампано у целини (М33)

- [II] 2013 **Ђорђевић (Слободан) Драгана**, Остојић (Станко) Ивана, Кукољ (Дане) Драган, Покрић (Мирослав) Маја, Дражић (Љубомир) Мирослава: *Multilayer Perceptrons Model For Image Quality Assessment*; 2013 21st Telecommunications Forum (TELFOR), Str: 765-768, ISBN: 978-1-4799-1420-3, IEEE Catalog Number CFP1398P-CDR

кратак опис садржине:

Овај рад представља процену квалитета слике употребом нелинеарног модела заснованог на неуронској мрежи, тачније вишеслојног перцептрона. Основни циљ процене је субјективна оцена квалитета слике уз помоћ тзв. Скале просечног оцењивања (МОС) користећи различите комбинације улазних параметара који представљају објективну метрику за процену квалитета мултимедијалног садржаја. У циљу тестирања перформанси модела и идентификације колико добро предложени модел процењује МОС, изабран је референтни линеарни модел (линеарна регресија). Поред тога, у раду се разматра како избор улазних података утиче на квалитет процене МОС.

- [III] 2014 **Ђорђевић (Слободан) Драгана**, Кукољ (Дане) Драган, Peter Schelkens: *Image Quality Assessment Using Takagi-Sugeno-Kang Fuzzy Model*; 2014 3rd International Conference on Image, Vision and Computing (ICIVC 2014), Paris, France; ICGIP proceedings (and included in SPIE Digital Library)

кратак опис садржине:

Основни циљ рада је представити модел за процену квалитета нелинеарне слике заснован на процени фази логике, односно Такаги-Сугено-Канг фази модела. Овај модел за процену квалитета слике користи кластерован простор улазних метрика. Главне предности уведеног модела квалитета су једноставност и разумљивост њених фази правила. Као

референтни модел изабран је модел полинома 3. реда. Параметри Такаги-Сугено-Канг фази модела су оптимизовани у складу са критеријумима мапирања изабраног сета улазних објективних мера квалитета на скали просечног мишљења (МОС).

- [IV] 2013 **Ђорђевић (Слободан) Драгана**, Покрић (Мирослав) Маја, Кукољ (Дане) Драган, Остојић (Станко) Ивана: *Image Quality Assessment Using Reduced-Reference Nonlinear Model*; 2013 IEEE 11th International Symposium on Intelligent Systems and Informatics (SISY); Str: 167-170, ISBN: 978-1-4799-0304-7, IEEE Hungary Section

кратак опис садржине:

У овом раду је приказана шема нелинеарног модела са смањеним референтним моделом која се заснива на статистичкој процени неуронске мреже, а то су вишеслојни перцептрони (МЛП) и која је оптимизована за скалу просечног резултата (МОС) за комбинацију различитог објективног квалитета улаза. Мере. У циљу испитивања перформанси модела и идентификације колико добро модел процењује МОС као референтни модел, бира се линеарни модел. Такође, у овом раду анализирани су ефекти селекције улазних мера на квалитет МОС процене.

- [V] 2014 **Ђорђевић (Слободан) Драгана**, Кукољ (Дане) Драган, Patrick Le Callet: *3D Image Quality Assessment Using Takagi-Sugeno-Kang Fuzzy Model*; IEEE 12th International Symposium on Intelligent Systems and Informatics (SISY 2014), Subotica, Serbia; IEEE Hungary Section

кратак опис садржине:

Овај рад анализира и представља утицај два типа објективних мера за процену квалитета слике, не-референтне и потпуне референтне мере, на квалитет перцепције 3Д слике користећи процену фази логике, односно Такаги-Сугено-Канг фази модела. На основу избора два типа улаза модела извршена је компаративна анализа. Сви параметри не-референтних и референтних Такаги-Сугено-Канг модела су оптимизовани у складу са одабраним критеријумима мапирања критеријума улазног објективног квалитета на одговарајуће Диференцијалне средње оцене мишљења (ДМОС).

- [VI] 2013 Toni Maki, **Ђорђевић (Слободан) Драгана**, Кукољ (Дане) Драган, Martin Varela: *A Reduced-Reference Parametric Model for Audiovisual Quality of IPTV Services*, 2013 Fifth International Workshop on Quality of Multimedia Experience (QoMEX), ISBN: 978-1-4799-0738-0, IEEE

кратак опис садржине:

У овом раду представљен је параметарски модел за процену аудиовизуелног квалитета у IPTV и сличних сервиса. Предложени модел користи карактеристике сигнала израчунате на пошиљаоцу (посебно повезане са нивоима кретања у садржају), као и параметарску процену, што га чини погодним за робусне апликације за надзор у реалном времену. Да би се добио модел праћена је методологија псеудо-субјективне процене квалитета (PSKA) и упоредна анализа различитих врста статистичких проценитеља, и то вишеслојни перцептрони (MLP) и насумичне неуронске мреже (RNN).

- [VII] 2013 **Ђорђевић (Слободан) Драгана**, Околишан Давид, Покрић (Мирослав) Маја, Ковач (Владимир) Јелена, Кукољ (Дане) Драган: *Toward Certification of 3D Video Quality of Experience through Inter-Laboratory Comparison*; 4th International Workshop on Perceptual Quality of Systems (PQS 2013), Vienna, Austria; Vol: , Br: , Str: 67-72, FTW Forschungszentrum Telekommunikation Wien GmbH

кратак опис садржине:

Брз развој и све већа употреба 3Д видео технологије повећава потребу за процесима стандардизације и сертификације када је у питању квалитет видео искуства. Због специфичних услова неопходних за висококвалитетну 3Д видео репродукцију, важну улогу у процени квалитета 3Д видеа игра фактор људског искуства. У циљу проналажења најбољих механизма за 3Д видео тестирање, неопходна је анализа постојећих објективних метода процене и предлог за субјективне процене које се могу потврдити. Овај рад сумира постојеће стандарде који се односе на општа међулабораторијска испитивања, испитује најбоље праксе за процену квалитета 3Д видео материјала из различитих лабораторија, а на

основу прикупљених савремених субјективних мерења предлаже универзални метод који се може користити као основа за поступак сертификације.

- [VIII] 2013 **Ђорђевић (Слободан) Драгана**, Кукољ (Дане) Драган, Остојић (Станко) Ивана, Околишан Давид, Драгана Сандић-Станковић: *3D image quality estimation (ANN) based on depth/disparity and 2D metrics*; 14th IEEE International Symposium on COMPUTATIONAL INTELLIGENCE and INFORMATICS, Budapest, Hungary; Vol: , Br: , Str: 125-130, ISBN: 978-1-4799-0194-4, IEEE Hungary Section

кратак опис садржине:

Главни циљ овог рада је да анализира и прикаже утицај метрике за процену квалитета објективне слике на перцепцију 3Д слике / видеа. Статистичка процена неуронске мреже је коришћена да се испита корелација између објективних мера на основу улазне слике и Диференцијалног средњег оцењивања (ДМОС) коришћене базе слике. У ту сврху коришћен је део LIVE 3D Image Quality Database. Резултати упућују на то да је поређење ДМОС процена неуронских мрежа засновано на пуној референтној и нереферентној метричкој методи показало веома слично понашање и тачност.

Национална пријава патента регистрована у Гласнику (M92)

- [IX] 2016 Кукољ (Дане) Драган, **Ђорђевић Чегар (Слободан) Драгана**, Бјелица (Здравко) Милан, Милошевић (Богдан) Милена: *Method for determining the emotional state of the user due to the visual impact*; Патента пријава П-2016/1174 6/2018; Br: 6, Завод за интелектуалну својину Републике Србије

кратак опис садржине:

Метод за одређивање емоционалног стања корисника услед визуелног утицаја, где се поступак састоји од корака аквизиције физиолошких података уз помоћ најмање једног биосензора, корака препроцесирања прикупљених података уз помоћ процесорске јединице, где се из њих добијају интерна обележја, корака прослеђивања наведених обележја у базу података на cloud-у и до улаза у модел који се такође налази на cloud-у, има

за новост да наведени модел представља адаптивни алгоритам сачињен из две фазе, где корак примене модела на интерна обележја добијена након корака, представља прву фазу модела, а као резултат добијају се предикције псеудо обележја на основу интерних обележја физиолошких сигнала, а у другој фаза је представљена кораком одређивања тренутног емоционалног стања на основу претходно добијених предикција псеудо обележја, али и на основу претходно добијених интерних обележја физиолошких сигнала, кораком слања добијеног стања на базу података на cloud-у као референтно стање за претходно послата интерна обележја, кораком трансформације стања корисника у одговарајућу препоруку за акцију.

Саопштење са скупа националног значаја штампано у изводу (М63)

- [X] 2014 Кукољ (Дане) Драган, **Ђорђевић (Слободан) Драгана**, Дражић (Љубомир) Мирослава, Витас (Милан) Милана, Остојић (Станко) Ивана: *Procena kvaliteta multimedijalnog sadržaja upotrebom različitih modela i metrika za estimaciju*; InterRegioSci 2014, 7. Научно-стручни скуп Нови Сад, 2014; Покрајински секретеријат за науку и технолошки развој

кратак опис садржине:

Основни циљ спроведених истраживања био је да се анализира и присутан утицај објективних метрике за процену перцепције квалитета мултимедије 3Д слике/видеа, 2Д слике и аудиовизуелних сервиса IPTV услуга. Опажени квалитет у великој мери зависи од компресије слике/видеа и брзине преноса, али и од садржаја. Пре свега, испитан је утицај објективних метрике за процену квалитета слике на перцепцију 3Д слике. Главни циљеви овог истраживања кретао се у смеру анализе утицаја објективних метрика без референтне слике и метрикама које поседују информације о свим референтним сликама у оквиру процене 3Д квалитета слике и перформанси мапирања одговарајућих нелинеарних модела за предвиђање квалитета. Тачније, испитан је укупан доживљај квалитета 3Д стереоскопске слике оштећене од кодирања и ефеката преноса, односно JPEG, JPEG2K, блуринг и фаст фединг ефекат. Такође, спроведено је истраживање базирано на процени квалитета 2Д слике употребом метрика заснованим на половичној информацији о референтној слици коистећи модел вишеслојне неуронске мреже (MLP). Коначно, анализиран је и

параметарски модела за процену аудиовизуелног квалитета заснован на метрикама са половићном информацијом о референтној слици. Модел је трениран уз помоћ методологије PSKA и то на подацима субјективне процене квалитета у оквиру IPTV сервиса. Процена тачности оцене квалитета која се заснива на MLP моделима показује да се пажљивом оптимизацијом, MLP може користити за изградњу прецизних аудиовизуелних модела

11 Литература

- [1] Harmon Jones E, Price T F, Gamble P A (2012). *The influence of the active states on cognitive brooding/narrowing: Considering the importance of motivational intensity*. Social and Personality Psychology Compass, vol. 6, no. 4, pp. 314-327, DOI 10.1111/j.1751-9004.2012.00432.x
- [2] Russell J A (1980). *A circumplex model of affect*. Journal of Personality and Social Psychology vol. 39, no. 6, pp. 1161–1178, DOI 10.1037/h0077714
- [3] Watson D, Tellegen A (1985). *Toward a consensual structure of mood*. Psychological Bulletin vol. 98, no. 2, pp. 219–235, DOI 10.1037/0033-2909.98.2.219
- [4] Thayer J F, Ahs F, Fredrikson M, Sollers III J J, Wager T D (2012). *A meta-analysis of heart rate variability and neuroimaging studies: Implications for heart rate variability as a marker of stress and health*. Neuroscience and Biobehavioral Reviews 36, pp. 747–756, DOI 10.1016/j.neubiorev.2011.11.009
- [5] Barreda-Ángeles M, Pépion R, Bosc E, LeCallet P, Pereda-Baños A (2014). *Exploring the effects of 3D visual discomfort on viewers' emotions*. 2014 IEEE International Conference on Image Processing (ICIP), pp. 753-757, DOI 10.1109/ICIP.2014.7025151
- [6] Bradley M, Lang P (1994). *Measuring emotion: The self-assessment Manikin and the semantic differential*. Journal of Behavior Therapy and Experimental Psychiatry, vol. 25, no. 1, pp. 49–59, DOI 10.1016/0005-7916(94)90063-9
- [7] Stickel C, Holzinger A, Felfernig A (2011). *Measuring Emotions: Towards rapid and low cost methodologies*. ACM Conference on Recommender Systems, Chicago, United States, 23/10/11.
- [8] Swangnetr M, Kaber D B (2013). *Emotional State Classification in Patient–Robot Interaction Using Wavelet Analysis and Statistics-Based Feature Selection*. IEEE Transactions On Human-Machine Systems, vol. 43, No. 1, pp 63-75, DOI 10.1109/TSMCA.2012.2210408
- [9] Dawson M E, Schell A M, Fillion D L (2000). *The Electrodermal System*. Chapter 8 in Handbook of Psychophysiology, 2nd ed. Cambridge University Press ISBN 62634X, pp. 200-223
- [10] Feldman L A (1995). *Valence Focus and Arousal Focus: Individual Differences in the Structure of Affective Experience*. Journal of Personality and Social Psychology Vol. 69, No. 1, 153-166, DOI 10.1037/0022-3514.69.1.153

-
- [11] Eibe F, Hall M A, and Witten I H (2016). *The WEKA Workbench. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques*. The WEKA Workbench. Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, 4th Edition, 2016, eBook ISBN: 9780128043578
- [12] Chung L, Yoo S K, Yoonj P, Namhyun K, Keesam J, Byungchae L (2005). *Using Neural Network to Recognize Human Emotions from Heart Rate Variability and Skin Resistance*. Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Conference 5. 5523-5. 10.1109/IEMBS.2005.1615734.
- [13] Lisetti C L, Nasoz F (2004). *Using Noninvasive Wearable Computers to Recognize Human Emotions from Physiological Signals*. EURASIP J. Adv. Signal Process. 2004: 929414, pp. 1672-1687, DOI 10.1155/S1110865704406192
- [14] Millan J D R, Mourino J, Franze M, Cincotti F, Varsta M, Heikkonen J, Babiloni F (2002). *A local neural classifier for the recognition of EEG patterns associated to mental tasks*. IEEE Transactions on Neural Networks Volume: 13, Issue: 3, May 2002, Print ISSN: 1045-9227 Electronic ISSN: 1941-0093, pp 678-686, DOI 10.1109/TNN.2002.1000132
- [15] Greene S, Thapliyal H, Caban-Holt A (2016). *A Survey of Affective Computing for Stress Detection: Evaluating technologies in stress detection for better health*. IEEE Consumer Electronics Magazine Volume: 5, Issue: 4, Oct. 2016, Print ISSN: 2162-2248, Electronic ISSN: 2162-2256, pp. 44-56, DOI 10.1109/MCE.2016.2590178
- [16] Mandryk R L, Atkins M S (2007). *A fuzzy physiological approach for continuously modelling emotion during interaction with play technologies*. International Journal of Human-Computer Studies 65, 2007, pp. 329–347, DOI 10.1016/j.ijhcs.2006.11.011
- [17] Schrauf M, Simon M, Schmidt E, Kincses W (2011). *Assessing drivers' fatigue state under real traffic conditions using EEG alpha spindles*. Proceedings of the Sixth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design, Vol 6., DOI 10.17077/drivingassessment.1374
- [18] Cernea D, Olech P S, Ebert1 A, Kerren A (2011). *Controlling In-Vehicle Systems with a Commercial EEG Headset: Performance and Cognitive Load*. Proceedings of IRTG 1131 – Visualization of Large and Unstructured Data Sets Workshop 2011. pp. 113–122, DOI 10.4230/OASIS.VLUDS.2011.113
- [19] Drachen A, Nacke L E, Yannakakis G, Lee Pedersen A (2010). *Correlation between Heart Rate, Electrodermal Activity and Player*. Proceeding Sandbox '10 Proceedings of the 5th ACM SIGGRAPH Symposium on Video Games, pp. 49-54, DOI 10.1145/1836135.1836143

-
- [20] Lin C T, Wu R C, Liang S F, Chao, Yu-Jie Chen W H, Jung T P (2005). *EEG-based drowsiness estimation for safety driving using independent component analysis*. IEEE Transactions on Circuits and Systems I: Regular Papers, Volume: 52, Issue: 12, pp. 2726 – 2738, DOI 10.1109/TCSI.2005.857555
- [21] Jirayucharoensak S, Pan-Ngum S, Israsena P (2014). *EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation*. The Scientific World Journal 627892. DOI 10.1155/2014/627892.
- [22] Sun H, Bi L, Bisheng C, Yinjing G (2015). *EEG-based Safety Driving Performance Estimation and Alertness Using Support Vector Machine*. International Journal of Security and Its Applications Vol. 9, No. 6, pp. 125-134, DOI 10.14257/ijisia.2015.9.6.13
- [23] Hyun Suk K, Daesub Y, Hyun S S, Park C H (2018). *Predicting the EEG Level of a Driver Based on Driving Information*. IEEE Transactions On Intelligent Transportation Systems, pp. 1524-9050, DOI 10.1109/TITS.2018.2848300
- [24] Klotzsche F, A Mariola, Hofmann S M, Nikulin V V, Villringer A, Michael G (2018). *Using EEG to Decode Subjective Levels of Emotional Arousal during an Immersive VR Roller Coaster Ride*. IEEE Conference on Virtual Reality, DOI 10.1109/VR.2018.8446275
- [25] Kim A, Chang M, Yeseul C, Sohyeon J & Kyoungmin L (2018). *The Effect of Immersion on Emotional Responses to Film Viewing in a Virtual Environment*. 25th IEEE Conference on Virtual Reality and 3D User Interfaces, pp. 601-602. 10.1109/VR.2018.8446046.
- [26] Wang C, Lo Y, Huang C (2016). *Exploration of video art and colour vision: The application of image change in digital interaction*. International Conference on Advanced Materials for Science and Engineering (ICAMSE), Tainan, 2016, pp. 512-515, DOI 10.1109/ICAMSE.2016.7840185
- [27] Sivagowry S (2014). *A Pragmatic Approach of Preprocessing the Data Set for Heart Disease Prediction*. International Journal of Innovative Research in Computer and Communication Engineering Vol. 2 Issue 11, 3297, pp. 6457-6465, ISSN 2320-9798
- [28] Kwon M, Kang J, Lee M (2013). *Emotion classification in movie clips based on 3D fuzzy GIST and EEG signal analysis*. International Winter Workshop on Brain-Computer Interface, Gangwo, South Korea, pp. 67-68, DOI 10.1109/IWW-BCI.2013.6506633
- [29] Matias Kivikangas J, Ekman I, Chanel G, Järvelä S, Cowley B, Salminen M, Henttonen P, Ravaja N (2011). *Review on psychophysiological methods in game research*. Journal of Gaming & Virtual Worlds vol. 3, no. 3, pp. 181-199, DOI 10.1386/jgvw.3.3.181_1

-
- [30] Soleymani M, Asghari-Esfeden S, Fu Y, Pantic M, (2016). *Analysis of EEG Signals and Facial Expressions for Continuous Emotion Detection*. IEEE Transactions on Affective Computing, vol. 7, no. 1, pp. 17-28, DOI 10.1109/TAFFC.2015.2436926
- [31] Ooi J S K, Ahmad S A, Chong Y Z, Ali S H M, Ai G, Wagatsuma H, (2016). *Driver emotion recognition framework based on electrodermal activity measurements during simulated driving conditions*. IEEE Conference on Biomedical Engineering and Sciences (IECBES), Kuala Lumpur, pp. 365-369, DOI 10.1109/IECBES.2016.7843475
- [32] Hu H, Zhu Z, Gao Z, Zheng R (2018). *Analysis on Biosignal Characteristics to Evaluate Road Rage of Younger Drivers: A Driving Simulator Study*. IEEE Intelligent Vehicles Symposium (IV), Changshu, pp. 156-161, DOI 10.1109/IVS.2018.8500444
- [33] Bala Sundar V, Devi T, Saravanan N (2012). *Development of a Data Clustering Algorithm for Predicting Heart*. International Journal of Computer Applications (0975 – 888) Volume 48 - No.7, June 2012, DOI 10.5120/7358-0095
- [34] Sugaya M, Watanabe I, Yoshida R, Chen F (2018). *Human Emotional State Analysis During Driving Simulation Experiment Using Bio-Emotion Estimation Method*. 2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC), Tokyo, Japan, pp. 589-594, DOI 10.1109/COMPSAC.2018.10301
- [35] Dabas H, Sethi C, Dua C, Dalawat M, Sethia D (2018). *Emotion Classification Using EEG Signals*. CSAI '18 Proceedings of the 2018 2nd International Conference on Computer Science and Artificial Intelligence, Shenzhen, China, pp. 380-384, DOI 10.1145/3297156.3297177
- [36] Boucsein W (1992). *Electrodermal activity*. Plenum Press, New York, DOI 10.1007/978-1-4757-5093-5
- [37] Brunnström K, Beker S A, De Moor K, Dooms A, Egger S, et al. (2013). *Qualinet White Paper on Definitions of Quality of Experience*. Output from the fifth Qualinet meeting Novi Sad, Serbia 2013. European Network on Quality of Experience, Vol 1.2, pp. 6-7, HAL Id: hal-00977812
- [38] Berne R M, Levy M N (2000). *Principals of Physiology*, 3rd ed. St. Louis, Mosby
- [39] Hoßfeld T, Skorin-Kapov L, HEEgaard P E et al. (2018). *A new QoE fairness index for QoE management*. Qual User Exp 3, 4 <https://doi.org/10.1007/s41233-018-0017-x>
- [40] Hoßfeld T, HEEgaard P E, Skorin-Kapov L et al. (2020). *Deriving QoE in systems: from fundamental relationships to a QoE-based Service-level Quality Index*. Qual User Exp 5, 7 <https://doi.org/10.1007/s41233-020-00035-0>

-
- [41] Hewage C, Ekmekcioglu E, (2020). *Multimedia Quality of Experience (QoE): Current Status and Future Direction*. Future Internet 2020, 12, 121.
- [42] Bradley M M, Lang P J (2007). *The International Affective Picture System (IAPS) in the study of emotion and attention*. Series in affective science. Handbook of emotion elicitation and assessment, New York, NY, US: Oxford University Press. pp. 29-46
- [43] Ravaja N (2004). *Contributions of psychophysiology to media research: Review and recommendations*. Media Psychology, 6(2), pp. 193-235, DOI 10.1207/s1532785xmep0602_4
- [44] Lang A, Potter R F, Bolls P (2009). *Where psychophysiology meets the media: Taking the effects out of mass media research*. Media effects: Advances in theory and research 3rd ed., New York, NY: Routledge, pp. 185-206
- [45] Holzinger A, Bruschi M, Eder W (2013). *On Interactive Data Visualization of Physiological Low-Cost-Sensor Data with Focus on Mental Stress*. Multidisciplinary Research and Practice for Information Systems, Springer Lecture Notes in Computer Science, LNCS 8127, Heidelberg, Berlin, Springer, pp. 469-480, DOI 10.1007/978-3-642-40511-2_34
- [46] Stickel C, Ebner M, Steinbach-Nordmann S, Searle G, Holzinger A (2009). *Emotion Detection: Application of the Valence Arousal Space for Rapid Biological Usability Testing to Enhance Universal Access*. Stephanidis, Constantine (ed.) Universal Access in Human-Computer Interaction. Addressing Diversity, Lecture Notes in Computer Science, LNCS 5614. Berlin, Heidelberg: Springer, pp. 615-624, DOI 10.1007/978-3-642-02707-9_70.
- [47] Stickel C, Ebner M, Holzinger A (2010). *The XAOS Metric - Understanding Visual Complexity as Measure of Usability*. Lecture Notes in Computer Science, LNCS 6389. Berlin, Heidelberg: Springer, pp. 278-290, DOI 10.1007/978-3-642-16607-5_18
- [48] Costadopoulos N, Tien D, Islam M Z, (2019). *Discovering Emotional Logic Rules from Physiological Data of Individuals*. In Proc. of the 18th International Conference on Machine Learning and Cybernetics (ICMLC), Kobe, Japan, pp. 468-474
- [49] Miranda-Correa J A, Abadi M K, Sebe N, Patras I (2017). *AMIGOS: A Dataset for Affect, Personality and Mood Research on Individuals and Groups*. ArXiv e-prints
- [50] Koelstra S, Muehl C, Soleymani M, Lee J-S, Yazdani A, Ebrahimi T, Pun T, Nijholt A, Patras I (2011). *DEAP: A Database for Emotion Analysis using Physiological Signals*. IEEE Transaction on Affective Computing, Special Issue on Naturalistic Affect Resources for System Building and Evaluation, in press

-
- [51] Xing L (2013). *Towards Reliable Stereoscopic, 3D Quality Evaluation*. Thesis for the degree of Philosophiae Doctor, Norwegian University of Science and Technology, Faculty of Information Technology, Trondheim, August 2013
- [52] Varela M, Skorin-Kapov L, Ebrahimi T (2014). *Quality of Service Versus Quality of Experience*. In: Möller S., Raake A. (eds) *Quality of Experience*. T-Labs Series in Telecommunication Services. Springer, Cham. https://doi.org/10.1007/978-3-319-02681-7_6
- [53] Gutiérrez Sánchez A (2016), *Analysis of quality of experience in 3D video systems*. Thesis for the degree of Philosophiae Doctor, Spain, Universidad Politécnica de Madrid
- [54] Barreda-Ángeles M, Pépion R, E. Bosc, Le Callet P, Pereda-Baños A (2014). *How visual discomfort affects 3DTV viewers' emotional arousal*, 2014 3DTV-Conference: The True Vision - Capture, Transmission and Display of 3D Video (3DTV-CON), Budapest, 2014, pp. 1-4, doi: 10.1109/3DTV.2014.6874718.V-CON),2014, Jul2014,Budapest,Bulgaria. pp.1–4, 10.1109/3DTV.2014.6874718.hal-01059975
- [55] Perkis A, You J, Xing L, Ebrahimi T, De Simone F, Rerabek M, Nasiopoulos P, Mai Z, Pourazad M T, Brunnström K, Wang K, Andrén B (2012). *Towards certification of 3D video quality assessment*. Conference: 6th Int. Workshop Video Processing and Quality Metrics for Consumer Electronics (VPQM)At: Scottsdale, AZ, USA, January 2012
- [56] Kroupi E, Hanhart P, Lee J et al. (2016). *Modeling immersive media experiences by sensing impact on subjects*. *Multimed Tools Appl* 75, 12409–12429 (2016). <https://doi.org/10.1007/s11042-015-2980-z>
- [57] Zhijun C, Wu, Zhang Y, Huang Z, Ran B, Zhong M, Lyu N (2015). *Feature Selection with Redundancy-complementariness Dispersion*. CoRR abs/1502.00231
- [58] Osowski S, Siwek K, Markiewicz T, (2004). *MLP and SVM networks - a comparative study*. Proceedings of the 6th Nordic Signal Processing Symposium, 2004. NORSIG 2004., Espoo, Finland, 2004, pp. 37-40.
- [59] Stickel C, Ebner M, Steinbach-Nordmann S, Searle G, Holzinger A (2009). *Emotion Detection: Application of the Valence Arousal Space for Rapid Biological Usability Testing to Enhance Universal Access*. In: Stephanidis C. (eds) *Universal Access in Human-Computer Interaction. Addressing Diversity*. UAHCI 2009. Lecture Notes in Computer Science, vol 5614. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-02707-9_70
- [60] Dehkordi A B (2015). *3D Video Quality Assessment*, Thesis for the degree of Philosophiae Doctor, The Faculty Of Graduate And Postdoctoral Studies Electrical & Computer Engineering, The University Of British Columbia, Vancouver

-
- [61] Hewage C, Martini M G (2013). *Quality of experience for 3D video streaming*. in IEEE Communications Magazine, vol. 51, no. 5, pp. 101-107, May 2013, doi: 10.1109/MCOM.2013.6515053.
- [62] Kroupi E, Hanhart P, Lee J, Rerabek M, Ebrahimi T (2014). *EEG correlates during video quality perception*. 2014 22nd European Signal Processing Conference (EUSIPCO), Lisbon, 2014, pp. 2135-2139.
- [63] Arapakis I, Barreda-Ángeles M, Pereda-Baños A (2019). *Interest as a Proxy of Engagement in News Reading: Spectral and Entropy Analyses of EEG Activity Patterns*. In IEEE Transactions on Affective Computing, vol. 10, no. 1, pp. 100-114, 1 Jan.-March 2019, doi: 10.1109/TAFFC.2017.2682089.
- [64] Perrin A F, Rerabek M, Ebrahimi T (2016). *Towards prediction of Sense of Presence in immersive audiovisual communications*. Electronic Imaging 2016(16), DOI: 10.2352/ISSN.2470-1173.2016.16.HVEI-128, Conference: Human Vision and Electronic Imaging (HVEI) 2016
- [65] Akhtar Z, Siddique K, Rattani A, Lutfi A L, Falk T H. (2019). *Why is Multimedia Quality of Experience Assessment a Challenging Problem?* In IEEE Access, vol. 7, pp. 117897-117915, 2019, doi: 10.1109/ACCESS.2019.2936470
- [66] Moller S, Engelbrecht K, Kuhnel C, Wechsung I, Weiss B (2009). *A taxonomy of quality of service and Quality of Experience of multimodal human-machine interaction*. 2009 International Workshop on Quality of Multimedia Experience, San Diego, CA, 2009, pp. 7-12, doi: 10.1109/QOMEX.2009.5246986.
- [67] De Moor K, Ketyko I, Joseph W et al. (2010). *Proposed Framework for Evaluating Quality of Experience in a Mobile, Testbed-oriented Living Lab Setting*. Mobile Netw Appl 15, 378–391 <https://doi.org/10.1007/s11036-010-0223-0>
- [68] Reichl P, Tuffin B, Schatz R (2013). *Logarithmic laws in service quality perception: where microeconomics meets psychophysics and quality of experience*. Telecommun Syst 52, 587–600 <https://doi.org/10.1007/s11235-011-9503-7>
- [69] Urvoy M, Barkowsky M, Le Callet P (2013). *How visual fatigue and discomfort impact 3D-TV quality of experience: a comprehensive review of technological, psychophysical, and psychological factors*. Ann. Telecommun. 68, 641–655 <https://doi.org/10.1007/s12243-013-0394-3>

-
- [70] Terzić K, Hansard M (2016). *Methods for Reducing Visual Discomfort in Stereoscopic 3D: A Review*. Signal Processing Image Communication 47 Follow journal, DOI: 10.1016/j.image.2016.08.002
- [71] Kani-Zabihi E, Hussain N, Mesfin G et al (2020). *On the influence of individual differences in cross-modal Multimedia QoE*. Multimed Tools Appl <https://doi.org/10.1007/s11042-020-09757-x>
- [72] Perkis A, Munkeby S, Hillestad O I (2006). *A model for measuring quality of experience*. In Proc. 7th Nordic Signal Process. Symp., 2006, pp. 198-201.
- [73] Kim H J, Lee K H, Zhang J (2010). *In-service feedback QoE framework*. In Proc. 3rd Int. Conf. Commun. Theory, Rel., Qual. Service, 2010, pp. 135-138.
- [74] De Moor K, Ketyko I, Deryckere T, De Marez L, Martens L, Verleye G, Joseph W (2010). *Proposed framework for evaluating quality of experience in a mobile, testbed-oriented living lab setting*. Mobile Netw. Appl., vol. 15, no. 3, pp. 378-391, 2010.
- [75] Song W, Tjondronegoro D, Docherty M (2012). *Understanding user experience of mobile video: Framework, measurement, and optimization*. Mobile Multimedia-User and Technology Perspectives. Rijeka, Croatia: InTech, 2012, pp. 1-30.
- [76] Reichl P, Tuffn B, Schatz R (2013). *Logarithmic laws in service quality perception: Where microeconomics meets psychophysics and quality of experience*. Telecommun. Syst. J., vol. 52, no. 2, pp. 587-600, 2013.
- [77] Doumanoglou A, Griffin D, Serrano J, Zioulis N, Phan T K, Jiménez D, Zarpalas D, Alvarez F, Rio M, Daras P (2018). *Quality of experience for 3-D immersive media streaming*. IEEE Trans. Broadcast., vol. 64, no. 2, pp. 379-391, Jun. 2018.
- [78] Laghari K, Crespi N, Connelly K (2012). *Toward total quality of experience: A QoE model in a communication ecosystem*. IEEE Commun. Mag., vol. 50, no. 4, pp. 58-65, Apr. 2012.
- [79] Falk T H, Pomerantz Y, Laghari K, Möller S, Chau T (2012). *Preliminary findings on image preference characterization based on neurophysiological signal analysis: Towards objective QoE modeling*. Proc. 4th Int. Workshop Qual. Multimedia Exper. pp. 146-147.
- [80] Moldovan A N, Ghergulescu I, Weibelzahl S, Muntean C H (2013). *User-centered EEG-based multimedia quality assessment*. Proc. IEEE Int. Symp. Broadband Multimedia Syst. Broadcast, Jun. 2013, pp. 1-8.
- [81] Perez J, Delechelle E (2013). *On the measurement of image quality perception using frontal EEG analysis*. Proc. Int. Conf. Smart Commun. Netw. Technol., 2013, pp. 1-5.

-
- [82] Battisti F, Carli M, Le Callet P, Paudyal P (2018). *Toward the assessment of quality of experience for asymmetric encoding in immersive media*. IEEE Trans. Broadcast., vol. 64, no. 2, pp. 392-406, Jun. 2018.
- [83] Sawahata J, Morita T (2018). *Estimating depth range required for 3-D displays to show depth-compressed scenes without inducing sense of unnaturalness*. IEEE Trans. Broadcast., vol. 64, no. 2, pp. 488-497, Jun. 2018.
- [84] Narwaria M (2018) *Toward better statistical validation of machine learning based multimedia quality estimators*. IEEE Trans. Broadcast., vol. 64, no. 2, pp. 446-460, 2018.
- [85] ITU-T Rec. P.10. (2008). *Vocabulary for performance and quality of service, Amendment 2: New definitions for inclusion in Recommendation ITU-T P.10/G.100*. Int. Telecomm. Union, Geneva, 2008.
- [86] Möller S (2010). *Quality Engineering - Qualität kommunikationstechnischer Systeme*. Springer, Berlin, 2010.
- [87] Fiedler M, Hoßfeld T, Tran-Gia P (2010). *A Generic Quantitative Relationship Between Quality of Experience and Quality of Service*. Network, IEEE, vol. 24, no. 2, pp. 36 –41, March-April, 2010.
- [88] Hoßfeld T, Schatz R, Varela M, Timmerer C(2012). *Challenges of QoE Management for Cloud Applications*. IEEE Communications Magazine, vol. 50, no. 4, Apr. 2012.
- [89] Baraković S, Skorin-Kapov L (2013). *Survey and Challenges of QoE Management Issues in Wireless Networks*. Journal of Computer Networks and Communications. 2013: 1–28. doi:10.1155/2013/165146.
- [90] Seufert M, Egger S, Slanina M, Zinner T, Hobfeld T, Tran-Gia P (2015). *A Survey on Quality of Experience of HTTP Adaptive Streaming*. IEEE Communications Surveys and Tutorials. 17 (1): 469–492. doi:10.1109/COMST.2014.2360940. ISSN 1553-877X.
- [91] Roto V, Law E, Vermeeren A, Hoonhout J (2011). *User Experience White Paper. Outcome of the Dagstuhl Seminar on Demarcating User Experience*. Dagstuhl, Germany, 2011.
- [92] Jekosch U (2005). *Voice and Speech Quality Perception — Assessment and Evaluation*. Springer Series in Signals and Communication Technology, Berlin, 2005.
- [93] ITU-T Recommendation P.10/G.100 (2006). *Amendment 1 Vocabulary for performance and quality of service Amendment 1: New Appendix I – Definition of Quality of Experience (QoE)*
- [94] W3C Emotion Incubator Group (2007). Incubator Group Report 10 July 2007.

- [95] Opozda S, Arkadiusz S (2014). *The survey of subjective and objective methods for quality assessment of 2D and 3D images*. Theoretical and Applied Informatics, Theoretical and Applied Informatics, ISSN 1896-5334, Vol. 26 (2014), no. 1,2 , pp. 39-67
- [96] Nehmé Y, Farrugia J P, Dupont F, Le Callet P, Lavoué G (2019). *Comparison of subjective methods, with and without explicit reference, for quality assessment of 3D graphics*. ACM Symposium on Applied Perception 2019, Barcelona, Spain. pp.1-9, 10.1145/3343036.3352493
- [97] Kukolj D (2007). *Sistemi zasnovani na računarskoj inteligenciji*, monografija, Univerzitet u Novom Sadu, Fakultet Tehničkih nauka; 26, ISBN 978-86-7892-068-4
- [98] ITU-T BT.500 (2019) *Methodologies for the subjective assessment of the quality of television images*
- [99] Chen E (2012). *RMIT3DV: Pre-announcement of a creative commons uncompressed HD 3D video database*. Proceedings of the 4th International Workshop on Quality of Multimedia Experience (QoMEX 2012). doi: 10.1109/QoMEX.2012.6263873
- [100] Orange Open Movie Team (2006). *Elephants dream*. Retrieved from: <http://www.elephantsdream.org/>
- [101] Đorđević Čegar D, Barreda-Ángeles M, Le Callet P, Kukolj D (2020). *Modelling Effects of S3D Visual Discomfort in Human Emotional State Using Data Mining Techniques*, ISSN 1380-7501, Springer - Multimedia Tools and Applications, 1-27
- [102] Đorđević Čegar D, Ostojić I, Kukolj D, Pokrić M, Dražić M (2013). *Mutilayer Perceptrons Model For Image Quality Assessment*; 2013 21st Telecommunications Forum (TELFOR), Str: 765-768, ISBN: 978-1-4799-1420-3, IEEE Catalog Number CFP1398P-CDR
- [103] Đorđević Čegar D, Kukolj D, Peter Schelkens (2014). *Image Quality Assessment Using Takagi-Sugeno-Kang Fuzzy Model*; 2014 3rd International Conference on Image, Vision and Computing (ICIVC 2014), Paris, France; ICGIP proceedings (and included in SPIE Digital Library)
- [104] Đorđević Čegar D, Pokrić M, Kukolj D, Ostojić I (2013). *Image Quality Assessment Using Reduced-Reference Nonlinear Model*; 2013 IEEE 11th International Symposium on Intelligent Systems and Informatics (SISY); Str: 167-170, ISBN: 978-1-4799-0304-7, IEEE Hungary Section
- [105] Đorđević Čegar D, Kukolj D, Patrick Le Callet (2014). *3D Image Quality Assessment Using Takagi-Sugeno-Kang Fuzzy Model*; IEEE 12th International Symposium on Intelligent Systems and Informatics (SISY 2014), Subotica, Serbia; IEEE Hungary Section

- [106] Maki T, Đorđević Čegar D, Kukolj D, Varela M (2013). A Reduced-Reference Parametric Model for Audiovisual Quality of IPTV Services, 2013 Fifth International Workshop on Quality of Multimedia Experience (QoMEX), ISBN: 978-1-4799-0738-0, IEEE
- [107] Đorđević Čegar D, Okolišan D, Pokrić M, Kovač J, Kukolj D (2013). *Toward Certification of 3D Video Quality of Experience through Inter-Laboratory Comparison*; 4th International Workshop on Perceptual Quality of Systems (PQS 2013), Vienna, Austria; Vol: , Br: , Str: 67-72, FTW Forschungszentrum Telekommunikation Wien GmbH
- [108] Đorđević Čegar D, Kukolj D, Ostojić I, Okolišan D, Sandić Stanković D (2013). *3D image quality estimation (ANN) based on depth/disparity and 2D metrics*. 14th IEEE International Symposium on COMPUTATIONAL INTELLIGENCE and INFORMATICS, Budapest, Hungary; Vol: , Br: , Str: 125-130, ISBN: 978-1-4799-0194-4, IEEE Hungary Section
- [109] Kukolj D, Đorđević Čegar D, Bjelica M, Milošević M (2016). *Method for determining the emotional state of the user due to the visual impact*. Патента пријава П-2016/1174 6/2018; Br: 6, Завод за интелектуалну својину Републике Србије
- [110] Kukolj D, Đorđević Čegar D, Dražić M, Vitas M, Ostojić I (2014). *Procena kvaliteta multimedijalnog sadržaja upotrebom različitih modela i metrika za estimaciju*. InterRegioSci 2014, 7. Научно-стручни скуп Нови Сад, 2014; Покрајински секретеријат за науку и технолошки развој

12 Спољње везе

- [a] <https://www.3d-contournet.eu/about-us/>
- [b] http://www.qualinet.eu/index.php?option=com_content&view=article&id=2&Itemid=2
- [c] <http://www.elephantsdream.org/>
- [d] <http://www.w3.org/2005/Incubator/emotion/XGR-emotion> visited last on 2011/07/29
- [e] <https://www.itu.int/rec/R-REC-BT.500>

План третмана података

Овај Образац чини саставни део докторске дисертације, односно докторског уметничког пројекта који се брани на Универзитету у Новом Саду. Попуњен Образац укоричити иза текста докторске дисертације, односно докторског уметничког пројекта.

План третмана података

| Назив пројекта/истраживања |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| TR32034 Развој програмске подршке за сажимање података заснован на методама рачунарске интелигенције |
| Назив институције/институција у оквиру којих се спроводи истраживање |
| а) Факултет техничких наука Универзитета у Новом Саду б) Научно истраживачки институт РТ-РК в) Политехнички факултет у Нанту (<i>Polytech Nantes, a French 'Grande École'</i>) |
| Назив програма у оквиру ког се реализује истраживање |
| Short Term Scientific Missions - 3D-ConTourNet - ICT COST Action IC1105 |
| 1. Опис података |
| <p>1.1 Врста студије</p> <p><i>Укратко описати тип студије у оквиру које се подаци прикупљају</i></p> <p>Студија испитује потенцијал могућности техника машинског учења у сврху предвиђања психофизичког стања људи приликом конзумирања мултимедијалног садржаја.</p> <p>1.2 Врсте података</p> <p>а) квантитативни</p> |

б) квалитативни

1.3. Начин прикупљања података

а) анкете, упитници, тестови

б) клиничке процене, медицински записи, електронски здравствени записи

в) генотипови: навести врсту _____

г) административни подаци: статистички подаци

д) узорци ткива: навести врсту _____

ђ) снимци, фотографије: 3Д видео запис

е) текст: литературни записи

ж) мапа, навести врсту _____

з) остало: описати _____

1.3 Формат података, употребљене скале, количина података

1.3.1 Употребљени софтвер и формат датотеке:

а) Excel фајл, датотека – .xlsx

б) SPSS фајл, датотека _____

в) PDF фајл, датотека _____

д) Текст фајл, датотека – .txt

е) JPG фајл, датотека _____

ф) Остало, датотека – .mat , EEG, EPG

1.3.2. Број записа (код квантитативних података)

а) број варијабли: велики број

б) број мерења (испитаника, процена, снимака и сл.) 18 испитаника, 162 узорка

1.3.3. Поновљена мерења

а) да

б) не

Уколико је одговор да, одговорити на следећа питања:

- а) временски размак између поновљених мера је _____
- б) варијабле које се више пута мере односе се на _____
- в) нове верзије фајлова који садрже поновљена мерења су именоване као _____

Напомене: _____

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

- а) *Да*
- б) *Не*

Ако је одговор не, образложити _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

Методологија прикупљања података је креирана према добрим праксама, стога је првенствено креиран мерни инструмент – упитник.

2.1.1. У оквиру ког истраживачког нацрта су подаци прикупљени?

- а) **експеримент: тестирање неуронских мрежа**
- б) **корелационо истраживање: Упоредна анализа психо-физиолошких мера различитим статистичким методама корелације**
- ц) **анализа текста, навести тип: Систематски преглед литературе**
- д) остало, навести шта _____

2.1.2 *Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).*

Self-Assessment Manikin

ITU-T Rec. P.10 (Amendment 2, 2008)

2.2 Квалитет података и стандарди

2.2.1. Третман недостајућих података

а) Да ли матрица садржи недостајуће податке? **Да** Не

Ако је одговор да, одговорити на следећа питања:

- а) Колики је број недостајућих података? **Део података за 6 испитаника**
- б) Да ли се кориснику матрице препоручује замена недостајућих података? **Да** Не
- в) Ако је одговор да, навести сугестије за третман замене недостајућих података

Поновљено снимање употребом истих мерних уређаја

2.2.2. На који начин је контролисан квалитет података? Описати

Употребом прецизних сензора за снимање психо-физиолошких података и провером референтних вредности приликом тест снимања.

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Референтни уноси и упоредна анализа.

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у посебном репозиторијуму на истом медијуму на коме је предата докторска дисертација.

3.1.2. URL адреса

3.1.3. DOI

3.1.4. Да ли ће подаци бити у отвореном приступу?

- а) Да
- б) Да, али после ембарга који ће трајати до

в) **Не**

Ако је одговор не, навести разлог

Због дељених права као и осетљивости података везаних за снимање психо-физиолошких података.

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложење

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен?

/ _____

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум. /

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? **Неограничено**

3.3.2. Да ли ће подаци бити депоновани под шифром? **Да Не**

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? **Да Не**

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да Не

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с људима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? Да Не

Ако је одговор Да, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да Не

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- а) **Подаци нису у отвореном приступу**
- б) **Подаци су анонимизирани**
- ц) **Остало, навести шта**

5. Доступност података

5.1. Подаци ће бити

- а) *јавно доступни*
- б) *доступни само уском кругу истраживача у одређеној научној области*
- ц) **затворени**

План третмана података

Ако су подаци доступни само уском кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Драгана Ђорђевић Чегар, draganasdj@gmail.com

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Драгана Ђорђевић Чегар, draganasdj@gmail.com

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

/