

УНИВЕРЗИТЕТ У БЕОГРАДУ  
ФАКУЛТЕТ ОРГАНИЗАЦИОНИХ НАУКА

Фархад Лотфи

**Сервиси паметног здравства за мерење и предвиђање  
стреса студената у високошколском образовању  
применом вештачке интелигенције**

Докторска дисертација

Београд, 2025. године

UNIVERSITY OF BELGRADE  
FACULTY OF ORGANIZATIONAL SCIENCES

FARHAD LOTFI

**Smart Healthcare Services for Detecting and Predicting  
Students' Stress in Higher Education  
Using Artificial Intelligence**

Doctoral Dissertation

Belgrade, 2025

Mentor:

**Prof.dr Zorica Bogdanović,**

redovni profesor Univerziteta u Beogradu – Fakulteta organizacionih nauka

Članovi komisije:

**Prof.dr Marijana Despotović-Zrakić,**

redovni profesor Univerziteta u Beogradu – Fakulteta organizacionih nauka

**Prof.dr Dragan Vukmirović,**

redovni profesor Univerziteta u Beogradu – Fakulteta organizacionih nauka

**Prof.dr Zoran Ševarac,**

redovni profesor Univerziteta u Beogradu – Fakulteta organizacionih nauka

**Prof.dr Ivana Kovačević,**

redovni profesor Univerziteta u Beogradu – Fakulteta organizacionih nauka

**Prof.dr Artur Bjelica,**

redovni profesor Medicinskog fakulteta Univerziteta u Novom Sadu

Datum odbrane: \_\_\_\_\_

# **SERVISI PAMETNOG ZDRAVSTVA ZA MERENJE I PREDVIĐANJE STRESA STUDENATA U VISOKOŠKOLSKOM OBRAZOVANJU PRIMENOM VEŠTAČKE INTELIGENCIJE**

## **Sažetak:**

Predmet istraživanja ove doktorske disertacije je razvoj modela i servisa pametnog zdravstva (*smart healthcare*) za merenje i predviđanje stresa studenata u visokoškolskom obrazovanju korišćenjem metoda i tehnika veštačke inteligencije, kako bi se unapredio kvalitet obrazovnog procesa u gotovo realnom vremenu (*biofeedback*). Cilj istraživanja je razviti metodološki postupak, projektovati i implementirati servise pametnog zdravstva zasnovane na metodama i tehnikama veštačke inteligencije, koji se mogu integrisati sa sistemom za e-učenje, koji omogućuju efektivnu i brzu detekciju i predviđanje stresa studenata, kao podrške obrazovnom procesu.

Anksioznost kod studenata u visokom obrazovanju je aktuelan problem, koji je dobio na značaju od početka Covid-19 pandemije. Osim širih društvenih problema, uticaj na stres ili anksioznost studenata imaju brojni faktori ponašanja poput ličnih osobina pojedinca, zatim pušenja cigareta ili fizičke aktivnosti, kao i faktori vezani za obrazovno okruženje.

Metode veštačke inteligencije, specifično mašinskog učenja se često koriste za detekciju i predviđanje stresa i anksioznosti. Mašinsko učenje se može koristiti kao efikasna tehnologija koja može predvideti stres ili anksioznost studenata sa velikom preciznošću. Otkrivanje stresa ili anksioznosti u ranim fazama je ključno za kliničke postupke kako bi se poboljšala atmosfera u društvu, posebno među studentkinjama. Ova disertacija ima za cilj da predviđa anksioznost studenata koristeći algoritme mašinskog učenja obezbeđujući relevantne povratne informacije. Ovo istraživanje takođe teži da proceni i poboljša preciznost detektovanja stresa i anksioznosti specifično kod studentkinja sa intervencijom tri ključne karakteristike: pušenje cigareta, fizička aktivnost i njihovu prosečnu ocenu na studijama koristeći algoritme i funkcije mašinskog učenja.

U istraživanju su učestvovali studenti sa Univerziteta u Beogradu. Učesnici su ispunili standardni upitnik poznat kao Inventar anksioznosti osobina i stanja (*STAI*). Podaci su analizirani primenom algoritma linearne regresije, višestruke linearna regresija, KNN, *k-means*. Ispitani su faktori korelacije i validnost razvijenog modela. Rezultati pokazuju da pušenje cigareta, fizička aktivnost, i prosečna ocena tokom studiranja utiču na stres kod studenata. Identifikovana su dva klastera anksioznosti kod studentkinja, pokazujući karakteristike koje su u stanju da detektuju anksioznost kod studentkinja sa velikom preciznošću.

**Ključne reči:** Pametno zdravstvo, Veštačka inteligencija, Mašinsko učenje, Stres i anksioznost.

# **SMART HEALTHCARE SERVICES FOR DETECTING AND PREDICTING STUDENTS' STRESS IN HIGHER EDUCATION USING ARTIFICIAL INTELLIGENCE**

## **Abstract**

The research subject of this doctoral dissertation is the development of smart healthcare models and services for measuring and predicting student stress in higher education using artificial intelligence methods and techniques, in order to improve the quality of the educational process in near real-time (biofeedback). The goal of the research is to develop a methodological procedure, and propose smart healthcare services based on artificial intelligence methods and techniques, which can be integrated with the e-learning system, and enable effective and quick detection and prediction of student stress, as support for the educational process.

Anxiety among students in higher education is a topical problem, which has gained special importance since the beginning of the Covid-19 pandemic. In addition to broader social issues, the stress or anxiety of students are influenced by numerous behavioral factors such as the individual's characteristics, smoking cigarettes or physical activity, as well as aspects related to the educational environment.

Artificial intelligence methods, specifically machine learning, are often used to detect and predict stress and anxiety. Machine learning can be used as an effective technology that accurately predicts students' stress or anxiety. Detecting stress or anxiety in the early stages is crucial for clinical procedures to improve the atmosphere in society, especially among female students. This dissertation aims to predict student anxiety using machine learning algorithms by providing relevant feedback. This research also aims to evaluate and improve the accuracy of detecting stress and anxiety specifically in female students with the intervention of three key characteristics: cigarette smoking, physical activity and their average grade in studies using algorithms and machine learning functions.

Students from the University of Belgrade participated in the research. Participants completed a standardized questionnaire known as the State Trait Anxiety Inventory (STAI). The data were analyzed using the algorithm of linear regression, multiple linear regression, KNN, k-means. Correlation factors and validity of the developed model were examined. The results show that cigarette smoking, physical activity, and the average grade during studies influence stress in students. Two clusters of anxiety in female students were identified, showing characteristics that are able to detect anxiety in female students with high precision.

**Keywords:** Smart Healthcare, Artificial intelligence, Machine Learning, Stress and Anxiety.

# Sadržaj

1.	Uvod.....	7
2.	Pregled literature .....	11
2.1.	Pametna zdravstvena zaštita .....	11
2.2.	Internet inteligentnih uređaja u zdravstvu .....	14
2.3.	Anksioznost i merenje anksioznosti .....	16
2.3.1.	Merenje anksioznosti korišćenjem novih tehnologija.....	20
2.3.2.	Predviđanje anksioznosti u pametnoj zdravstvenoj zaštiti zasnovano na nosivim uređajima.....	20
2.4.	Mašinsko učenje i algoritmi u predviđanju stresa i anksioznosti .....	24
2.5.	Izazovi predviđanja anksioznosti primenom mašinskog učenja.....	32
2.6.	Pregled o otkrivanju anksioznosti kod mladih ili studenata korišćenjem mašinskog učenja	34
3.	Model ekosistema pametne zdravstvene zaštite za otkrivanje i predviđanje stresa studenata.....	38
4.	Metodološki postupak istraživanja .....	41
4.1.	Istraživački okvir .....	41
4.2.	Učesnici i instrumenti.....	44
4.3.	Analiza podataka .....	45
4.4.	Predobrada podataka.....	46
4.5.	Algoritmi i funkcije mašinskog učenja.....	47
5.	Analiza rezultata .....	54
6.	Diskusija .....	66
7.	Naučni i stručni doprinosi .....	69
8.	Budući rad .....	72
9.	Zaključak.....	73
9.1.	Prednosti .....	74
9.2.	Ograničenja istraživanja .....	74
10.	Dodatak A.....	76
11.	Reference.....	78

## 1. Uvod

Predmet ove disertacije je razvoj modela pametnih zdravstvenih usluga za otkrivanje i predviđanje stresa studenata u visokom obrazovanju metodama veštačke inteligencije.

Stres može biti privremena uznemirenost, dok anksioznost može da smeta osobi neko vreme i izazove nepopravljivu štetu [1], [2]. Anksioznost je bolest koja može biti uzrokovana stalnim stresom i ako se nastavi, može predstavljati ozbiljan rizik za pojedinca. Neke bolesti se javljaju u odrasloj dobi, ali u slučaju anksioznosti, može se pojaviti u detinjstvu i može biti opasna za ljude i društvo. Anksioznost ima negativan uticaj skoro na trećinu stanovništva, prema rezultatima istraživanja [2], [3].

Merenjem anksioznosti ispituju se fiziološki, bihevioralni i psiho-kognitivni aspekti [4]. Mnogi faktori mogu da utiču na povećanje stresa i anksioznosti među studentima, kao što su periodi ispitnih rokova, studentski život, troškovi života i slični problemi [5].

Istraživanja su takođe pokazala da stres i anksioznost mogu pogoršati fizičko i psihičko mentalno stanje studenata jer prolaze kroz ranjiv period u studentskom životu [6], [7]. Prema društvenom aspektu i u većini razvijenih zemalja, otkrivanje stresa ili anksioznosti u kontekstu elektronskih sistema je gotovo u realnom vremenu. Nivo anksioznosti i stresa pacijenata mere se primenom senzora i nosivih uređaja. Tačnost ovih sistema je preko 90%, što predstavlja veću preciznost u odnosu na tradicionalne sisteme [8].

Kao što je pomenuto, mladi različitih uzrasta su podložni anksioznosti, dok sa druge strane pojava novih tehnologija u njihovom životu ima pozitivne povratne informacije i povećava njihovu motivaciju [9].

Jedan od glavnih ciljeva ovog istraživanja je predviđanje anksioznosti studenata koristeći tehnologije mašinskog učenja (*Machine Learning – ML*) sa velikom tačnošću. Pristup analizi podataka o anksioznosti pomoću algoritama mašinskog učenja u dosadašnjim istraživanjima je bio uspešan. Naučni rezultati takođe ukazuju da je oko 35% pojedinaca širom sveta imalo povećanu anksioznost tokom *COVID-19* [10].

Studenti u visokom obrazovanju različitih uzrasta su podložni anksioznosti. Iako su neki javni problemi poput *COVID-19* imali različite efekte na stres ili anksioznost studenata, neki faktori ponašanja kao što su pušenje cigareta, fizičke aktivnosti i srodni faktori pokazali su različite uticaje na njihov stres ili stanja anksioznosti. Fizičke aktivnosti i vežbe mogu pomoći u smanjenju anksioznosti i poboljšanju opšteg mentalnog zdravlja. Pušenje cigareta takođe može povećati simptome stresa i anksioznosti među studentima [11]–[14]. Usvajanje e-učenja tokom *COVID-19* je postalo veoma rasprostranjeno, i u velikoj meri je zadržano i nakon pandemije. Delovi učenja u sistemima visokog obrazovanja se realizuju u kontekstu e-učenja, tako da se stres i anksioznost mogu analizirati i vrednovati u ovom okviru [15].

U ovoj disertaciji fokus je na prikupljanju podataka o stresu i anksioznosti studenata putem društvenih mreža, medija, upitnika itd. u kontekstu e-učenja. Nakon prikupljanja podataka,

sledi faza predprocesiranja, i analize podataka korišćenjem različitih algoritama veštačke inteligencije (*Artificial Intelligence - AI*).

Metode i alati veštačke inteligencije omogućavaju rešavanje složenih problema, prepoznavanje obrazaca i učenje iz iskustva. U oblasti *AI*, razvijaju se algoritmi zasnovani na analizi velikih količina podataka, koji zatim omogućuju uspešne predikcije i na osnovu manjih skupova podataka. Aplikacije zasnovane na veštačkoj inteligenciji uspešno detektuju i predviđaju različite pojave, omogućavajući personalizovane usluge i sisteme preporuka. Primena u kontekstu obrazovanja i smanjenja stresa ili anksioznosti studenata je samo jedna od oblasti u kojima se *AI* primenjuje. [16]. *AI* aplikacije uključuju virtualni kontekst i fizički kontekst. Virtualni kontekst je u stanju da poboljša učenje korišćenjem matematičkih algoritama, a fizički kontekst se koristi u pružanju zdravstvenih usluga [17]. Mašinsko učenje (*ML*) kao široko polje veštačke inteligencije koristi se za dijagnostikovanje mnogih fizičkih i mentalnih bolesti poput stresa i anksioznosti sa velikom tačnošću [18].

Postoji nekoliko faktora ili problema koji utiču na stres ili anksioznost studenata, kao što su demografski faktori, kao i faktori ponašanja. Stoga, korišćenje mašinskog učenja za otkrivanje anksioznosti studenata čini se efikasnim rešenjem, a ova metodologija je uspela da identificuje studente koji su skloni anksioznosti [18]. Za razliku od tradicionalnih metoda i algoritama, veštačka inteligencija, poput mašinskog učenja i algoritama dubokog učenja, uvedena je kako bi se ponudila bolja rešenja za brigu o studentima koji pate od takvih bolesti. Pronalaženje faktora sa najvećim uticajem korišćenjem metode regresione analize (*LASSO*) na anksioznost stanja i osobina nakon treninga bio je jedan od vitalnih praznina u ovom istraživanju.

Prema Svetskoj zdravstvenoj organizaciji (*SZO*), oko 450 miliona ljudi širom sveta pati od problema kao što su stres i anksioznost [19]. Mnogi faktori mogu izazvati anksioznost kod ljudi na radnom mestu, poput nesposobnosti da obavljaju radne zadatke, izbegavanja preuzimanja odgovornosti na poslu i slično [20]. Međutim, analiza podataka o stresu i anksioznosti pomoću tehnika mašinskog učenja postali su popularni i uspešni obrasci koji su otkriveni u ovom polju [21].

Štaviše, korišćenje mašinskog učenja za dijagnostikovanje mnogih fizičkih i mentalnih bolesti poput stresa i anksioznosti vrši se sa prihvatljivom tačnošću. Razorni značaj bolesti *COVID-19* na ponašanje studenata poslednjih godina je neosporiv. Stoga, korišćenje mašinskog učenja za otkrivanje anksioznosti studenata čini se efikasnim rešenjem, a ova metodologija je uspela da identificuje studente koji su skloni anksioznosti [18]. Studenti se suočavaju sa mnogim pitanjima kao što su obrazovanje i studentski život, i to tako da anksioznost može imati veći uticaj na živote mlađih ljudi. Podrazumeva se da je pandemija *COVID-19* pogoršala ovo pitanje poslednjih godina [18].

U studiji [22], faktori formiranja i pogoršanja anksioznosti praćeni su tokom perioda od 8 meseci tehnikama mašinskog učenja, i konačno je za to izdvojen povoljan obrazac. Na drugom mestu je takođe navedeno da optimalni rezultati u akademskom i kompanijskom okruženju zahtevaju opuštanje i okruženje bez stresa. Mašinsko učenje je obezbedilo modele

kao i obrasce koji mogu da predvide stres i anksioznost među ljudima u realnom vremenu [23].

Prisustvo drugih bolesti takođe može izazvati anksioznost [24]. Studije su pokazale da praćenje, kontrola i otkrivanje anksioznosti u pametnom okruženju mogu imati nekoliko koristi za društvo [25]. Obim podataka na osnovu kojih se analizira i predviđa anksioznost može biti veoma širok, pa primena mašinskog učenja može biti dobro rešenje.

Stres i anksioznost u akademskom kontekstu ugrožavaju mentalno zdravlje studenata, a specifično studentkinja [26], [27], zbog čega će u drugom delu studije fokus istraživanja biti na analizi i predviđanju stresa i anksioznosti studentkinja primenom algoritama i funkcija mašinskog učenja. Stres i anksioznost su uobičajene mentalne bolesti, pa je stres poznat kao privremeno stanje, a ako se nastavi, može se pretvoriti u anksioznost [28], [29].

Spielberger i koautori u svom radu o *STAI* testu, tvrde da je anksioznost kao stanje, eng. *state anxiety*, kratkoročni oblik stresa [30] dok se je dugoročna stabilna anksioznost deo osobina ličnosti i poznata je kao *trait anxiety*. Tokom pandemije *COVID-19*, anksioznost se pojačala, posebno među studentima na univerzitetu, a postoje ograničene informacije o anksioznosti studenata u ovom dobu [12]. Iako može biti teško predvideti i otkriti anksioznost kod mnogih pojedinaca na različitim mestima, tvrdi se da će analiza takvih podataka novim pristupima dati rezultate visoke tačnosti i osetljivosti [31], [32]. Primena mašinskog učenja kao jednog od uobičajenih pristupa za otkrivanje ili predviđanje anksioznosti i stresa privukla je pažnju istraživača u kontekstu detekcije stresa među studentkinjama [33]–[35]. U današnjem užurbanom svetu, detekcija anksioznosti korišćenjem mašinskog učenja i primenom različitih algoritama može imati pozitivan efekat i omogućiti ranu intervenciju [18].

Trenutno, zbog bolesti *COVID-19* i drugih problema sa velikim brojem aktivnosti studenata, mentalne bolesti poput anksioznosti su u porastu [36]– [38] i ako se ne proveravaju pažljivo, mogu imati mnoge negativne efekte na ponašanje pojedinaca [39]. Mašinskim učenjem moguće je ispitati velike količine podataka o anksioznosti kako bi je predvideo i otkrio koristeći algoritme nadziranog učenja [40].

Razdvajanje pola pojedinaca kod razmatranja anksioznosti kako bi se razumele razlike u najprikladnijoj psihijatrijskoj brzi smatra se neophodnim [41]. Pored toga, pušenje cigareta je često povezano sa većim rizikom od simptoma i znakova stresa i anksioznosti. Odnos između rizika od anksioznosti i pušenja među ljudima je dobro uspostavljen.

Pored toga, tvrdi se da je anksioznost jedan od ključnih razloga koji može nagnati studentkinje ka konzumiranju cigareta [11], [42], [43]. Takođe, značajan faktor je i fizička aktivnost. Bavljenje fizičkom aktivnošću uspelo je smanjiti anksioznost za 4%-7%, prema rezultatima istraživanja [44]. Takođe, u akademskim oblastima, studenti nakon završene srednje škole iskusili su osećaj anksioznosti sa manjom fizičkim aktivnostima [45]. Pored ovih razloga, redovno postoje veze između prosečne ocene tokom studiranja (eng. *Grade Point Average - GPA*) i anksioznosti studenata, tako da niži prosek ocena može izazvati dugoročnu anksioznost među studentima i studentkinjama [46], [47].

Da zaključimo, konzumiranje cigareta, fizička aktivnost i prosečna ocena tokom studiranja su uključene u ovo istraživanje kao faktori ponašanja koji mogu uticati na anksioznost. U ovoj disertaciji, u prvoj fazi, stres i anksioznost studenata su predviđeni korišćenjem tehnologije mašinskog učenja, a u drugoj fazi, detekcija stresa i anksioznosti studentkinja izvršena je putem *STAI* upitnika sa tri ključna faktora intervencije i ispitana korišćenjem algoritama mašinskog učenja.

Cilj istraživanja sprovedenog u ovoj doktorskoj disertaciji je bio da se kroz algoritme mašinskog učenja uz intervenciju tri značajne karakteristike: pušenja cigareta, fizičke aktivnosti i prosečne ocene tokom studiranja, poboljša detekcija stresa ili anksioznosti studenata i studentkinja u visokom obrazovanju.

Prednosti koje implementacija rezultata ove disertacije donosi:

- + Unapređenje usluga pametne zdravstvene zaštite, u smislu otkrivanja i predviđanja stresa studenata u visokom obrazovanju korišćenjem veštačke inteligencije
- + Primena modela mašinskog učenja za detekciju i predviđanje stresa ili anksioznosti studenata na univerzitetu i u vezi sa ključnim karakteristikama faktora ponašanja.
- + Poboljšanje predviđanja i otkrivanja stresa i anksioznosti specifično kod studentkinja.
- + Korišćenje algoritama veštačke inteligencije za kreiranje odgovarajuće povratne informacije (eng. *biofeedback*) i razvoj adaptivnog model reakcije u realnom vremenu za unapređenje mentalnog zdravlja studenata.
- + Poboljšanje iskustva studenata u obrazovnom sistemu zasnovano na primeni veštačke inteligencije.

Navedene prednosti postignute su organizacijom predloženog rešenja na sledeće zadatke:

- + Analiza mogućnosti primene nosivih sistema (eng. *wearable*) za procenu, analizu i skladištenje podataka o mentalnom zdravlju studenata i studentkinja.
- + Predlog za deljenje informacija o stresu ili anksioznosti sa lekarima, kao oblik integracije obrazovnih i zdravstvenih servisa.
- + Razvoj modela za poboljšanje sistema pametne zdravstvene zaštite.
- + Razvoj odgovarajuće klasifikacije i grupisanja skupova podataka prikupljenih *STAI* upitnikom u cilju boljeg razumevanja povratnih informacija o mentalnom zdravlju u realnom vremenu.
- + U zaključku, cilj je razviti obrazac ili model koji će omogućiti efikasnu i pouzdanu predikciju stresa i anksioznosti studenata i omogućiti povratnu spregu kojom se integrišu servisi pametnog zdravstva i visokoškolskog obrazovanja.

## 2. Pregled literature

### 2.1. Pametna zdravstvena zaštita

Pametno zdravstvo je novi koncept koji je privukao veliku pažnju u modernom svetu. Pametno zdravstvo se odnosi na upotrebu novih tehnologija u području zdravstva ili zdravstvene zaštite za dijagnostiku, upravljanje, kontrolu i lečenje mnogih bolesti [48], [49]. Pametna zdravstvena zaštita je deo novog načina života i jedna je od najvažnijih komponenti pametnog grada [50].

Rastući broj hroničnih bolesnika donosi veliki broj izazova za pacijente, zdravstveni sistem i regulatore. Jedan od pristupa za upravljanje i kontrolu hroničnih bolesti zasnovan je na pametnoj zdravstvenoj zaštiti i primeni interneta inteligenčnih uređaja (eng. *Internet of Things, IoT*) [51]. Jedna od primena servisa pametnog zdravstva odnosi se na otkrivanje i praćenje stresa i anksioznosti, ponašanja ljudi u kontekstu dijagnostike i upravljanja mentalnim bolestima (uključujući stres i anksioznost) [52]. Pametni uređaji, kao što su pametni satovi i *fitness* narukvice, koji omogućuju merenje različitih zdravstveno značajnih parametara, mogu biti adekvatan izbor za praćenje anksioznosti. Moderne tehnologije su sve više prihvачene među mladima, pa mogu biti primenjene za detekciju i upravljanje stresom u ovoj populaciji [8].

Razvoj tehnologija, kao što su *big data* tehnologije, računarstvo u oblaku, mobilne tehnologije i druge, dovele su do promena u tradicionalnim zdravstvenim informacionim sistemima. Važna tačka unutar zdravstvene zaštite je reagovanje na promene u realnom vremenu. Efikasnost inteligenčnih sistema u oblasti zdravlja i usluga je veoma važna zato što je analiza velikih podataka osnova za razvoj upotrebljivih inteligenčnih sistema. Servisi pametnog zdravstva mogu se koristiti za kontrolu na daljinu i upravljanje raznim bolestima, i da podatke o zdravstvenom stanju pacijenta šalju zdravstvenoj ustanovi i lekarima. Takođe, mogu se koristiti i za pružanje povratnih informacija pacijentima. U ovom kontekstu, elektronski uređaji, prenosivi uređaji i mobilno zdravstvo sa mogućnošću daljinskog nadgledanja, prijema zdravstvenih podataka od pacijenta i kontrolisanje stanja pacijenta igraju vitalnu ulogu [8], [48].

Pametno zdravstvo obuhvata širok spektar digitalnih servisa, ali se generalno može odnositi na zdravstvene sisteme zasnovane na mobilnom zdravstvu (*M-Health*) i elektronskom zdravstvu (*E-Health*), kao i na telemedicinu, čijim se razvojem došlo do koncepta pametnog zdravstva [48]. Pojam e-zdravstva se odnosi na medicinsku informatiku zasnovanu na primeni interneta i srodnih tehnologija, u kojoj se podaci smeštaju, čuvaju i koriste u digitalnom obliku. Stoga, elektronski zdravstveni zapisi (eng. *electronic health records, EHRs*) predstavljaju koncept u kojem su podaci iz zdravstvenog kartona pacijenta smešteni u elektronskom obliku, čime su dostupni za pregled i ocenu [53], [54].

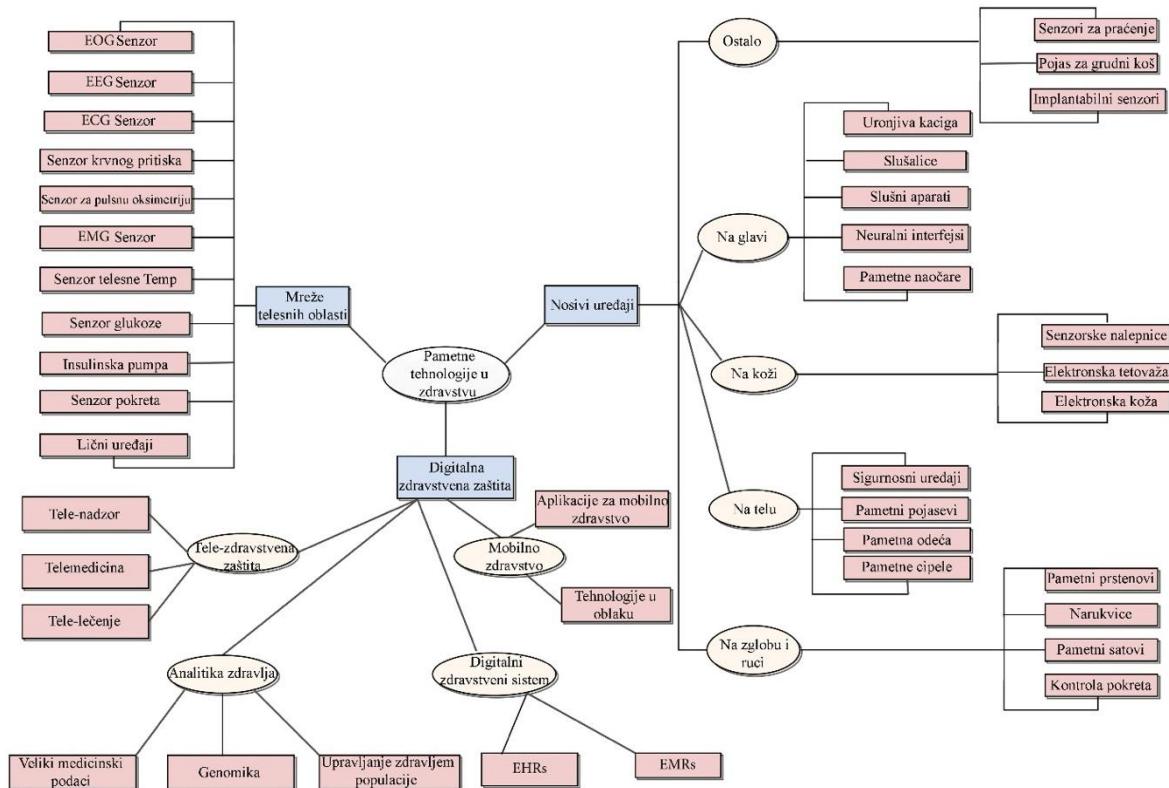
Mobilno zdravstvo je deo koncepta e-zdravstva koji se odnosi na korišćenje pametnih mobilnih telefona i mobilnih aplikacija, nosivih uređaja (eng. *wearables*) i drugih uređaja i

servisa zasnovanih na upotrebi mobilnih tehnologija. U mnogim slučajevima, mobilno zdravstvo je zasnovano na internetu inteligentnih uređaja. Biomedicinski senzori mogu meriti i beležiti velike količine podataka, kao što su otkucaji srca, temperatura, krvni pritisak, brzina disanja itd.

Više studija je pokazalo da mobilno zdravstvo može poboljšati kvalitet života [55]–[57], pri čemu veliki broj pacijenata je zadovoljan korišćenjem servisa elektronskog i mobilnog zdravstva. Pokazano je da primena servisa elektronskog i mobilnog zdravstva može osnažiti pacijente koji boluju od različitih bolesti [54]–[56]. Takođe, upotrebu servisa elektronskog zdravstva podržavaju i lekari, jer ovi servisi omogućuju unapređenje procesa poboljšanja zdravlja [58]. Podaci iz sistema e-zdravstva mogu se koristiti u zdravstvenim ustanovama, u osiguravajućim društvima, u okviru platformi za e-zdravstvo, za unapređenje rada hitnih službi, i za proveru i kontrolu stanja pacijenata [59]. Na osnovu analize karakteristika tradicionalnih zdravstvenih sistema, poteškoća i izazova u njihovom funkcionisanju, usvajanje savremenih pametnih rešenja zdravstvene zaštite prihvaćeno je kao pozitivan korak [60].

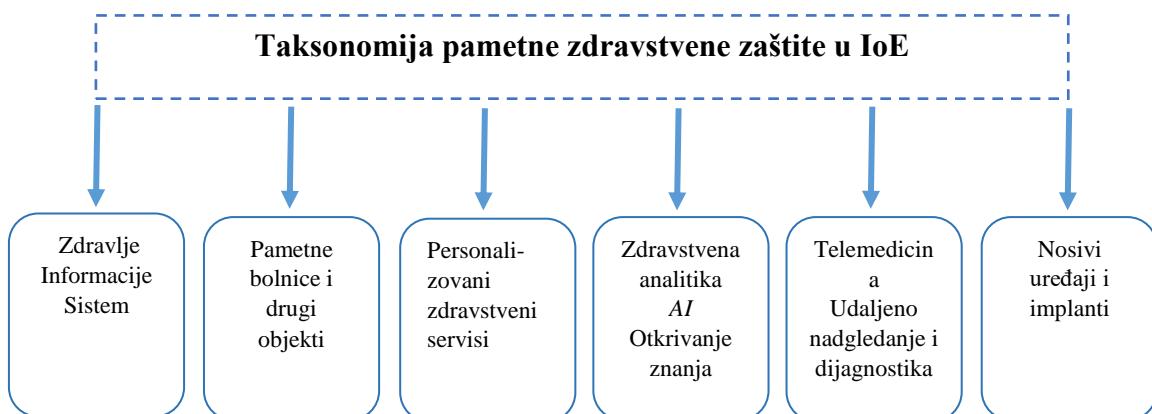
Chaudhary i koautori tvrde da su nosivi uređaji i senzori pozitivno delovali na praćenje stanja pacijenata i reagovanje u realnom vremenu, korišćenjem tehnologija i servisa interneta inteligentnih uređaja i veštačke inteligencije [60]. Na Slici 1 predstavljene su neke od primena i tehnologija pametne zdravstvene zaštite, kao što su mreže telesnih oblasti (eng. *body area network*), nosivi uređaji i servisi digitalne zdravstvene zaštite. Na primer, pametni uređaji omogućavaju pacijentima da prate svoje zdravstveno stanje, uključujući telesne parametre i simptome. Nosivi uređaji su klasifikovani u 5 kategorija, na osnovu toga kako se koriste: uređaji koji se nose na glavi, uređaji koji su ugrađeno u odeću, oni koji se nose na ručnom zglobovu, oni koji se stavlju direktno na kožu, kao i svi drugi uređaji koji uključuju senzore za praćenje, kaiševe za grudi, senzore ugrađene u implante, i drugo (Slika 1) [60].

Po ovoj klasifikaciji, servisi digitalne zdravstvene zaštite podeljeni su u 4 kategorije, uključujući servise mobilnog zdravstva, digitalni zdravstveni sistem, zdravstvenu analitiku i tehnologije telemedicine (Slika 1) [60].



Slika 1. Taksonomija nekih komponenti pametne zdravstvene zaštite zajedno sa studijom slučaja, sigurnošću okvira i budućih pravaca pristupa [60]

Kao proširenje pojma interneta inteligentnih uređaja, javlja se koncept Interneta svega (eng. *Internet of Everything*, *IoE*), koji obuhvata širi kontekst razvoja pametnih zdravstvenih okruženja. Ovaj koncept privlači pažnju istraživača i stručnjaka, u pogledu razvoja novih servisa, smanjenja troškova, i unapređenja zdravstvene zaštite u celini. Raj i saradnici su 2023. godine razvili taksonomiju sistema pametne zdravstvene zaštite visokih performansi, zasnovanu na rešenjima i izazovima u ovoj oblasti (Slika 2) [61].



Slika 2. Internet svega (IoE) zasnovan na taksonomiji pametne zdravstvene zaštite [61].

Takođe su pomenuli da Internet svega (*IoE*) koristi alate i tehnike veštačke inteligencije, poput metoda dubokog učenja za efikasno otkrivanje znanja [61].

Nosivi i ugrađeni uređaji definisani su kao mali, lako prenosivi uređaji, u stanju da lako prikupe podatke o fizičkoj aktivnosti, navikama spavanja, vitalnim znacima, i drugim metrikama vezanim za zdravlje pojedinca. Pružaoci zdravstvenih usluga mogu koristiti daljinsko praćenje i dijagnostiku kako bi pratili pacijente i dijagnostikovali stanja na osnovu podataka iz onlajn konteksta. Analiza podataka i veštačka inteligencija takođe uključuju tehnologije mašinskog učenja da analiziraju velike količine zdravstvenih podataka i da pomognu pri donošenju odluke. Takođe, zdravstveni tretmani i usluge zahtevaju personalizovanu medicinu prilagođenu jedinstvenom profilu, potrebama i preferencijama pacijenta, koristeći preciznu medicinu, genetsko testiranje i portale za pacijente. Konačno, pametne bolnice i objekti se pominju kao fizički prostor koji može da koristi *IoT* tehnologije za optimizaciju radnih tokova (Slika 2) [61]. U najširem kontekstu od interesa za ovu disertaciju, u pametne objekte i okruženja važna za praćenje stanja pacijenta, spadaju i njihovi domovi, radni prostor, pametni grad, i sl. U slučaju studentske populacije, deo sistema pametnog zdravstva postaju i obrazovne institucije, i drugi prostori i servisi koji su deo obrazovnog procesa. U ovoj disertaciji prikupljeni su podaci o anksioznosti studenata putem elektronskih platformi za učenje.

Opisano istraživanje potvrđuje da kada se podaci prikupljaju i čuvaju u elektronskom kontekstu, oni imaju odziv u realnom vremenu, poboljšavaju se performanse i zdravstveni servisi. Pametna zdravstvena zaštita stvorila je novu definiciju za zdravstvenu industriju. U ovoj disertaciji predstavljen je okvir za analizu stresa i anksioznosti pomoću tehnika mašinskog učenja, kao deo šireg konteksta pametnog zdravstva. Upotreba mašinskog učenja nad zdravstvenim podacima, kao što su podaci o anksioznosti, takođe predstavlja značajan deo sistema pametnog zdravstva [62].

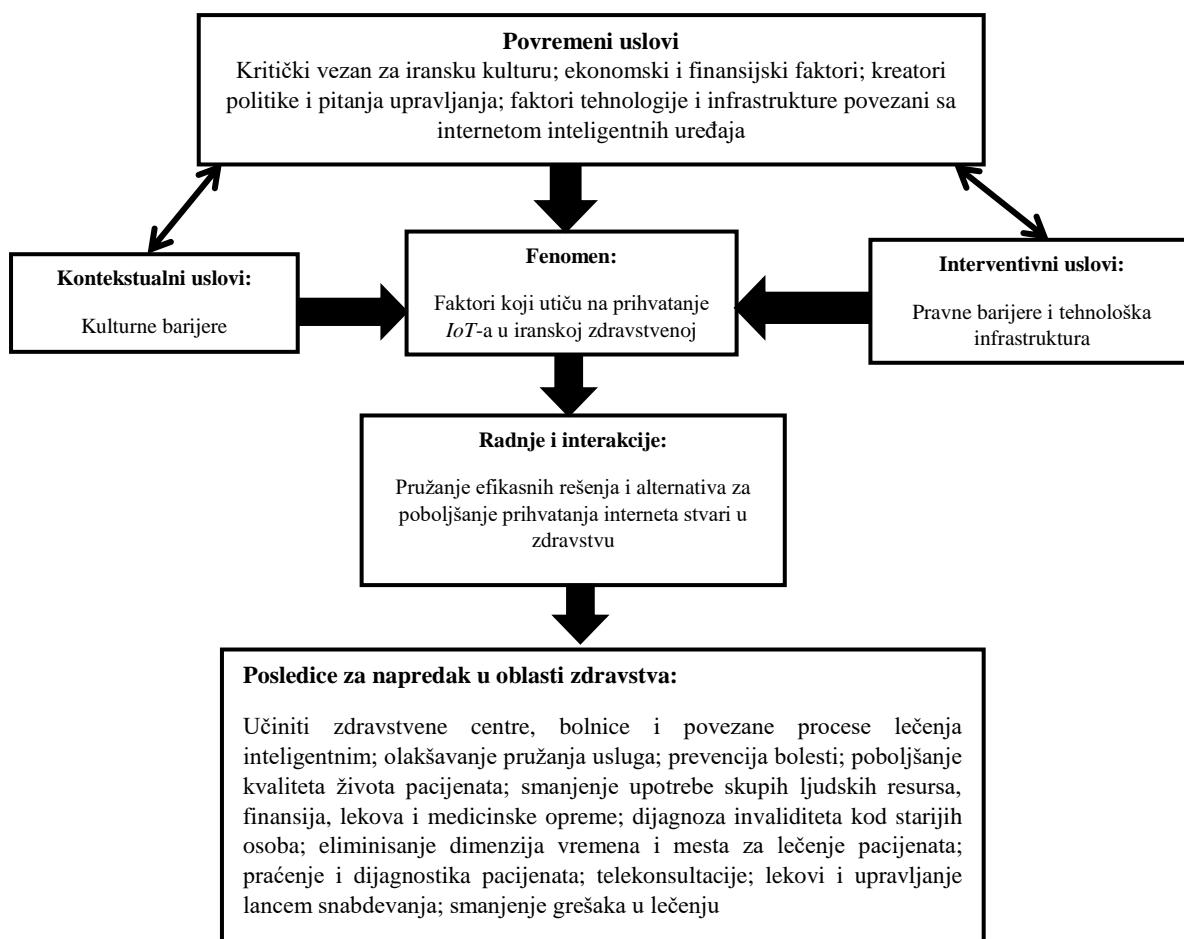
## 2.2. Internet intelligentnih uređaja u zdravstvu

Rezultati istraživanja koji su pokazali da internet intelligentnih uređaja ima brojne prednosti i pruža potencijalna rešenja za ublažavanje pritiska na zdravstvene sisteme [63]. Zbog toga je značajan deo rada usmeren na korišćenje *IoT* aplikacija u oblasti zdravstvene zaštite. Ove aplikacije omogućuju praćenje pacijenata sa specifičnim stanjima kao što su *Parkinson* [64], lečenje raka [65], kontinuirano praćenje glukoze (*CGM*) [66] ili dijabetes [67]. Iako se ova tehnologija može koristiti u internet okruženju i ponekad bez ljudskih intervencija, njen uspešna implementacija zahteva prihvatanje tehnologije od strane korisnika [68].

Istraživanja potvrđuju da *IoT* tehnologije mogu da mere fizičke parametre i da putem bežičnog interneta šalju poruku upozorenja, u vidu notifikacija ili elektronske pošte, a koja se zatim može dostaviti doktorima i sačuvati u elektronskom zdravstvenom kartonu. Platforma interneta intelligentnih uređaja *Node MCU* omogućuje evidenciju i pregled podataka koji se odnose na krvni pritisak, kiseonik, otkucaje srca, nivo šećera u krvi i tako dalje koristeći [68]. Integracija interneta intelligentnih uređaja i algoritmama dubokog učenja stvorila je snažan

sistem za daljinsko praćenje zdravlja koji omogućava naprednu analizu podataka i otkrivanje znanja. Takođe, praćenje procesa u realnom vremenu je takođe moguće. Odgovor sistema u realnom vremenu je jedan od čestih problema u zdravstvenim sistemima u bolnicama [69]. Sudeći po dokazima iz istraživanja, nadgledanje zdravstvenog stanja pacijenta bazirano se na IoT i analiziranje zdravstvenih podataka zahteva korišćenje većeg broja elektronskih uređaja i senzora [70].

*IoT* zasnovan na veštačkoj inteligenciji već godinama usvajaju bolnice, a intelligentni uređaji takođe igraju vitalnu ulogu u elektronskim zdravstvenim kartonima i pri opremanju soba za pacijente. Oko 30% ljudi u SAD-u ima ozbiljne bolesti poput dijabetesa, krvnog pritiska ili srčanih bolesti, a primena ovih tehnologije pruža više koristi jer omogućuje lečenja sa reakcijom u realnom vremenu [70]. Proučavanje faktora koji utiču na prihvatanje interneta intelligentnih uređaja među menadžerima u zdravstvu je prvi korak u primeni ove tehnologije. Na Slici 3 je objašnjen model prihvatanja interneta intelligentnih uređaja od strane zdravstvenih menadžera u Iranu.



Slika 3. Model prihvatanja interneta intelligentnih uređaja od strane zdravstvenih menadžera [71].

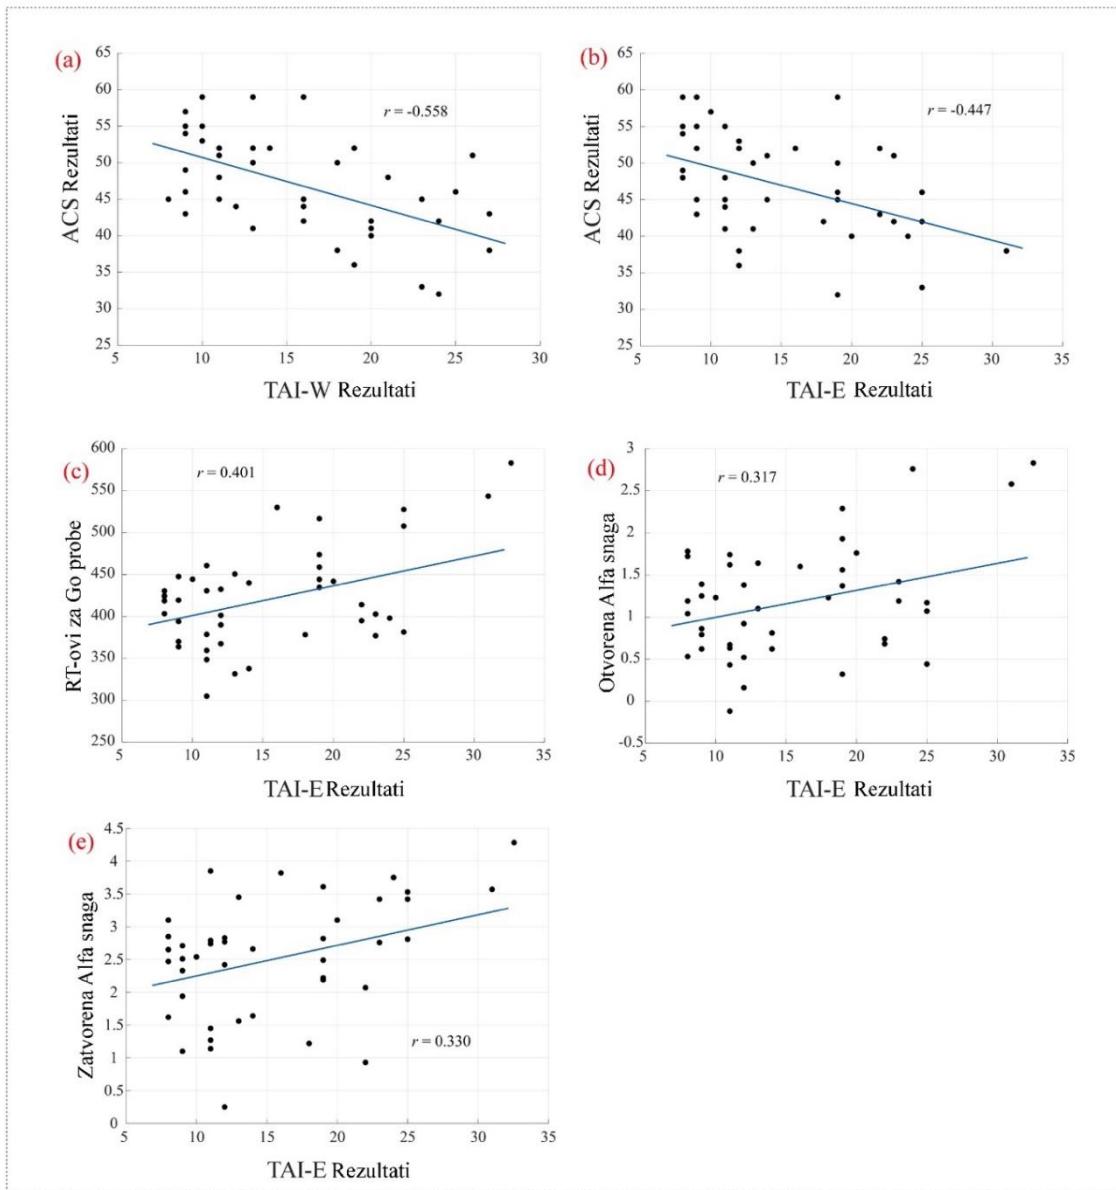
Korišćenjem interneta inteligenčnih uređaja, lekari mogu pratiti stanje pacijenata u svakom trenutku, proveravati njihove vitalne znake, sprečavati akutne bolesti i interakcije lekova, i na kraju smanjiti troškove lečenja. Prema važnosti uspostavljanja prihvatanja bilo koje tehnologije od strane korisnika, Khadivar je predložio način za identifikaciju i određivanje prioriteta faktorima koji utiču na prihvatanje *IoT*-a među zdravstvenim menadžerima koristeći različite metode. Kvalitativna metodologija koja se koristi u ovoj studiji poznata je kao deskriptivno-istraživačka metoda, osnovana teorija, i kvantitativna metodologija. Međutim, cilj je bio da se uspostavi model za prihvatanje interneta inteligenčnih uređaja od strane zdravstvenih menadžera u Iranu. Konačno, ovaj istraživački rad preporučuje razvoj odgovarajuće tehničke infrastrukture u kontekstu interneta inteligenčnih uređaja [71].

### **2.3. Anksioznost i merenje anksioznosti**

Jedan od mentalnih poremećaja značajan u današnje vreme je anksioznost. Anksioznost može doprineti razvoju mnogih drugih bolesti, i to je razlog zašto je privukao veliku pažnju istraživača [72].

Anksioznost je dijagnostikovana kao emocionalna reakcija pojedinca koja može biti patološka [2]. Srećom, anksioznost je poznata kao jedna od bolesti koja se može tretirati samokontrolom [73]. Pored toga, merenje, upravljanje i kontrola anksioznosti zahteva višegodišnji proces [74], a metode i tehnike mašinskog učenja u tome mogu pomoći. Tehnologija mašinskog učenja je kategorisana u inteligentne sisteme jer to omogućava računarima da treniraju iz skupova podataka kako bi poboljšali performanse modela [75].

Wei i Sun u svom istraživanju su istraživali deficit pažnje među tinejdžerima koristeći njihove *EEG* rezultate, podatke o ponašanju, i samoprocenu [76]. Oni su koristili ove faktore (ponašanje, samoprocene i *EEG* u stanju mirovanja) za ispitivanje i analizu u kontrolisanju pažnje adolescenata. Uzorak ankete su činili 42 adolescente, kojima su mogli da izvuku emotivne komponente i brigu kroz test anksioznosti. Emotivna komponenta je rezultirala pozitivno u odnosu na korelaciju za alfa moć. Štaviše, u metodološkom delu oni su koristili stanje mirovanja i *EEG* podatke da izmere Test anksioznosti (*TAI*) i upitnik o sebi (*ACS*) prilagođen kontekstu istraživanja. Slika 4 pokazuje korelaciju između emocionalnog stanja i zabrinutosti iz *ACS*, tako da *ACS* daje negativan rezultat u vezi sa *TAI-W* ( $p = 0.003$ ;  $r = -0.447$ ) [76].



Slika 4. Korelacija među komponentama prikazana je raspršenom grafikom.

- a: Korelacija između ACS i TAI-E rezultata; b: korelacija između ACS rezultata i TAI (TAI-E) rezultata; c: korelacija između RTs i TAI-E rezultata; d: korelacija između alfa parametra na mestu Pz elektrode i TAI-E rezultata (stanje otvorenih očiju); e: korelacija između alfa parametra na mestu Pz elektrode i TAI-E rezultata (stanje zatvorenih očiju) prikazano raspršenom grafikom [76].

Sve u svemu, Wei i Sun su tvrdili da zabrinutost u vezi sa ispitima može imati negativan uticaj i na samopouzdanje i sposobnost pažljive kontrole pojedinaca [76].

Tabela 1. Demografski podaci i dijagnoze [81].

Demografski	<b>N= 734 uzorka</b>	
Dečiji pol	% ženskog	43.2
Starost deteta (godine)		$M = 9.71$ SD = 3.34
Starost roditelja (godine)		$M = 40.06$ SD = 6.70
Školovanje dece		
U osnovnoj školi (%)		77.7
U srednjoj školi (%)		19.9
Nije u školi (%)		2.5
Nacionalnost		
Okeanski (%)		71.8
Severozapadna Evropa (%)		17.1
Južna i Istočna Evropa (%)		4.8
Ostalo (%)		6.3
Vrsta porodice	% oba roditelja	79.2
Porodični dohodak za većinu uzorak	% \$52,000-\$124,799	44.3
Odnos roditelja s detetom	% biološki roditelj	98.1
Dijagnoza/invaliditet <sup>a</sup>		
Bez dijagnoze (%)		34.8
Anksioznost (%)		38.6
Depresija (%)		5.0
Autistični poremećaj (%)		32.2
Aspergerov sindrom (%)		11.3
PDD-NOS (%)		3.4
ADHD (%)		14.0
ODD (%)		4.8
Poremećaj ponašanja (%)		0.1
Intelektualni invaliditet (%)		4.4
Ostalo (%)		9.9

Međutim, korišćenje inteligentnih sistema za otkrivanje stresa i anksioznosti ima više prednosti. Danas su istraživači uspeli da otkriju skalu percipirane anksioznosti korisnika procenjujući milione tвитова [77]. Prethodna istraživanja potvrdila su da su korisnici izrazili želju za korišćenjem društvenih medija, što pomaže da se identificuje njihova ličnost [78]. Detekcija anksioznosti pomoću mikro blogova postala je veoma precizna. Na primer, preko aplikacije X je generisano 500 miliona tвитова u 2017. godini sa više od 328 miliona aktivnih korisnika, 100 miliona dnevnih korisnika, a analiza ove količine velikih podataka može biti korisna u predviđanju anksioznosti [77], [79].

U 2023. godini, Lantos i saradnici su merili anksioznost kod odraslih kako bi uporedili efikasnost dugog i kratkog upitnika. Uporedili su zdravstvene upitnike pacijenata, inventar slabosti, generalizovane skale anksioznog poremećaja i Keslerove skale [80]. Za analizu performansi dužih verzija koristili su skale poput *K6 vs K10*, *Malaise-3 vs Malaise-9*, *GAD-2 vs GAD-7* i *PHK-2 vs PHK-9* za poređenje sa kratkim verzijama anksioznosti. U istraživanju je učestvovalo 987 odraslih osoba uzrasta između 18 i 86 godina iz slučajne i uzorkovane grupe u Ujedinjenom Kraljevstvu, a cilj je bio da se postigne tačnost skala i testira postojeća struktura osobina potrebna za procenu prilagođenosti modela. U drugom delu ovog istraživanja, koristili su isti model među mladim odraslima u poduzorku u kome je učestvovalo 375 učesnika između 18 i 39 godina. Rezultati su adresirali da kratke verzije mogu imati sličnosti sa punim verzijama [80].

Međutim, prethodno istraživanje se odnosilo na razvoj Mekvarijeve anksiozne skale ponašanja (*MABS*) za merenje i analizu anksioznosti među adolescentima i decom sa razvijenim spektrom autizma (*ASD*). U ovom slučaju, merenje je izvršeno na osnovu roditeljskih izveštaja za anksioznost [81]. Učesnici su odabrani među 734 roditelja dece uzrasta od 3 do 19 godina, pri čemu je anksioznost njihove dece bila od velikog značaja za njih. *MIMIC* modeliranje rezultiralo je da su skale očigledno drugačije među ne-*ASD* i *ASD* kategorijama. U takvu svrhu, oni su koristili tri različite kategorije od ukupno 429 roditelja (58.4%) uključujući i kontrolnu grupu, 64 roditelja (8.7%) uključujući i kliničku grupu koja traži pomoć za anksioznost i *ASD* grupu (roditelji čija deca imaju primarnu dijagnozu spektra autizma, N=242 [32.9%]). Tabela 1 prikazuje demografske karakteristike neurorazvojnog i mentalnog poremećaja i stanja tog istraživanja [81]. Sve u svemu, nova roditeljska mera (*MABS*) procenjivala je anksioznost kod dece i adolescenata, a rezultati su pokazali dobro uklapanje u predloženu strukturu karakteristika. Takođe je utvrđeno koji je *ASD* dobio pozitivan uticaj *MABS* stavki [81].

Pored pametnih tehnologija, standardni upitnici, merenje temperature kože, otkucaja srca i krvnog pritiska mogu biti korisni u otkrivanju anksioznosti i stresa [82]. Takođe, neki istraživači tvrde da postoje rodne razlike u količini generalizovanog stresa i anksioznosti, pri čemu žene često prijavljuju više znakova stresa i anksioznosti nego muškarci [83]. Simptomi stresa i anksioznosti kod žena tokom života prijavljeni su više nego kod muškaraca [84]. Dakle, zbog toga smo se u drugom delu ove studije fokusirali na stres i anksioznost studentkinja koristeći AI tehnike.

### **2.3.1. Merenje anksioznosti korišćenjem novih tehnologija**

Pametni uređaji kao deo moderne tehnologije poznati su po primeni u otkrivanju stresa i anksioznosti. Danas se tačnost detekcije poremećaja anksioznosti često procenjuje putem metrika profilisanja zasnovanih na podacima koji se prikupljaju pomoću pametnih telefona [85]. Na primer, digitalni biomarkeri se koriste za detekciju znakova anksioznosti koristeći senzore pametnih telefona i podatke prikupljene u realnom vremenu [86]. S druge strane, pored prednosti pametnih telefona, ovi uređaji su u stanju da izazovu socijalnu anksioznost i moraju se uzeti u intervencijske mere za efikasnu upotrebu [87]. Istraživanja pokazuju da uvođenje različitih elemenata informacionih sistema ili specifičnih aplikacija može dovesti do stresa kod zaposlenih, naročito u poslovnim okruženjima koja su po prirodi stresna [90]. Iz akademske perspektive, iskustva u podučavanju i analizi rezultata učenja pokazuju da *viva voce* ispiti koji koriste daljinsko snimanje mogu smanjiti anksioznost studenata ukoliko se tehnologija koristi na odgovarajući način i ispit organizuje u pozitivnoj atmosferi [91].

Anksioznost može imati različite efekte na zdravlje i može izazvati oboljenja srca, dijabetes, povišen krvni pritisak i druga oboljenja. Na primer, u zemljama Južne Azije, oko 9,8 miliona ljudi pati od anksioznih poremećaja [88]. Osećaj nemira, lako umaranje, nervosa, nadraženost, poteškoće u koncentraciji, glavobolja, bol u mišićima i bolovi u stomaku, pospanost i problemi sa spavanjem navedeni su kao česti znaci i simptomi stresa i anksioznosti kod pojedinaca [89].

U nastavku je predstavljena upotreba nosivih senzora za praćenje parametara anksioznosti i stresa, koji omogućavaju napredniji pristup tretmanu anksioznosti u poređenju sa tradicionalnim metodama [8].

### **2.3.2. Predviđanje anksioznosti u pametnoj zdravstvenoj zaštiti zasnovano na nosivim uređajima**

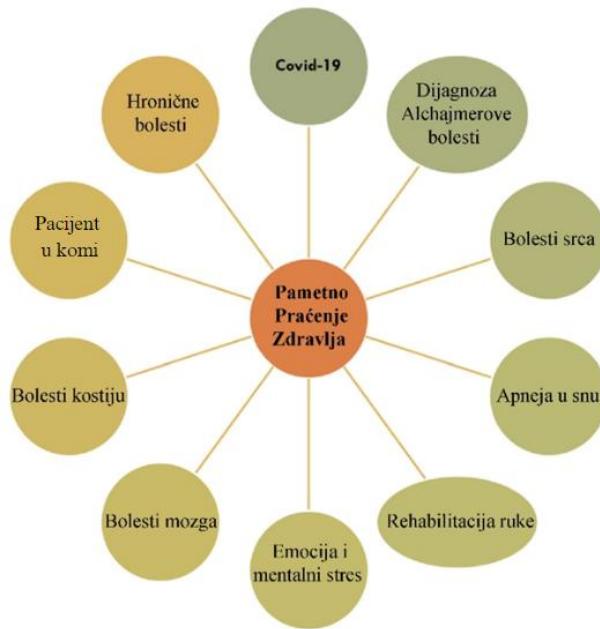
Korišćenje pametnih uređaja kao što su pametni mobilni telefoni i pametni satovi se stalno povećava. Zdravstveni podaci se prikupljaju i pripremaju za analizu pomoću ovih nosivih tehnologija, koristeći pametne mobilne telefone, tablete, računare i srodne elektronske uređaje. Pored toga, mobilno zdravstvo je prihvaćeno i kao jedna od najvažnijih tehnologija za praćenje i kontrolu mnogih bolesti [92]. Anksioznost je jedna od vrsta bolesti koja se može pratiti i kontrolisati ovim pametnim nosivim uređajima. Takođe, veštačka inteligencija igra efikasnu ulogu u promovisanju pametnog zdravstva kroz korisne programe [93].

Danas, pametno zdravstvo pozitivno utiče na mnoge bolesti kao što su anksioznost i stres. Na primer, u rezultatima studije [8], tvrdi se da korišćenje pametnih nosivih uređaja može značajno smanjiti procenat stresa i anksioznosti pacijenata. Pametni nosivi uređaji poput pametnih satova mogu detektovati i u mobilne zdravstvene aplikacije poslati podatke o vitalnim znacima kao što su telesna temperatura, krvni pritisak, različite vrste dijabetesa, broj otkucaja srca i srodni problemi. Stoga, ovo predstavlja jedan od važnih načina na koji ljudi danas mogu da mere svoju anksioznost putem mobilnih nosivih uređaja u okviru

zdravstvenog sistema [8], [94]. Studije su pokazale da je upravljanje anksioznošću kroz upotrebu nosivih tehnologija vrlo korisno, ali s druge strane, u nekim slučajevima je njihova upotreba zabranjena [95].

Danas se primenom mobilnih zdravstvenih aplikacija uz pomoć pametnih mobilnih telefona preduzimaju pozitivni koraci za smanjenje anksioznosti, a takve tehnologije takođe pružaju odgovor u realnom vremenu [96]. Na primer, da bi se poboljšao novi način života bez anksioznosti, tvrdi se da upotreba e-zdravlja i mobilnog zdravlja ima direktni uticaj na poboljšanje životnih uslova.

Rezultati istraživanja sa više od 1000 učesnika pokazali su da 47,2% koristi tehnologije elektronskog zdravstva, 23,2% koristi tehnologije mobilnog zdravstva 10,7% koristi nosivu tehnologiju. Međutim, sistemi nadgledanja preko pametnog zdravstva se razvijaju u kontekstu integracije *IoT*, i osim što se ubrzavaju dijagnoza i lečenje, takođe se smanjuju i troškovi lečenja. U sadašnjem dobu, jedna od najvažnijih primena pametne zdravstvene zaštite je predviđanje anksioznosti i stresa [49].



Slika 5. Neke ključne primene pametnog zdravstva [49].

Kao što je pomenuto na Slici 5, mentalne bolesti se mogu pratiti i kontrolisati u kontekstu pametnog zdravstva.

Pored navedenog, zbog sve većeg razvoja pametne zdravstvene zaštite (e-zdravlje i m-zdravlje), mladi su prihvatili širu primenu nosive tehnologije. Nalazi istraživanja potvrđuju da je postojanje e-zdravlja kao i mobilnog zdravlja povećalo nivo fizičke aktivnosti među mladima i motivisalo ih za obavljanje fizičkih aktivnosti [98]. U SAD-u je 2014. godine gotovo polovina studenata bila frustrirana, navodi se u izveštaju Američkog zdravstvenog

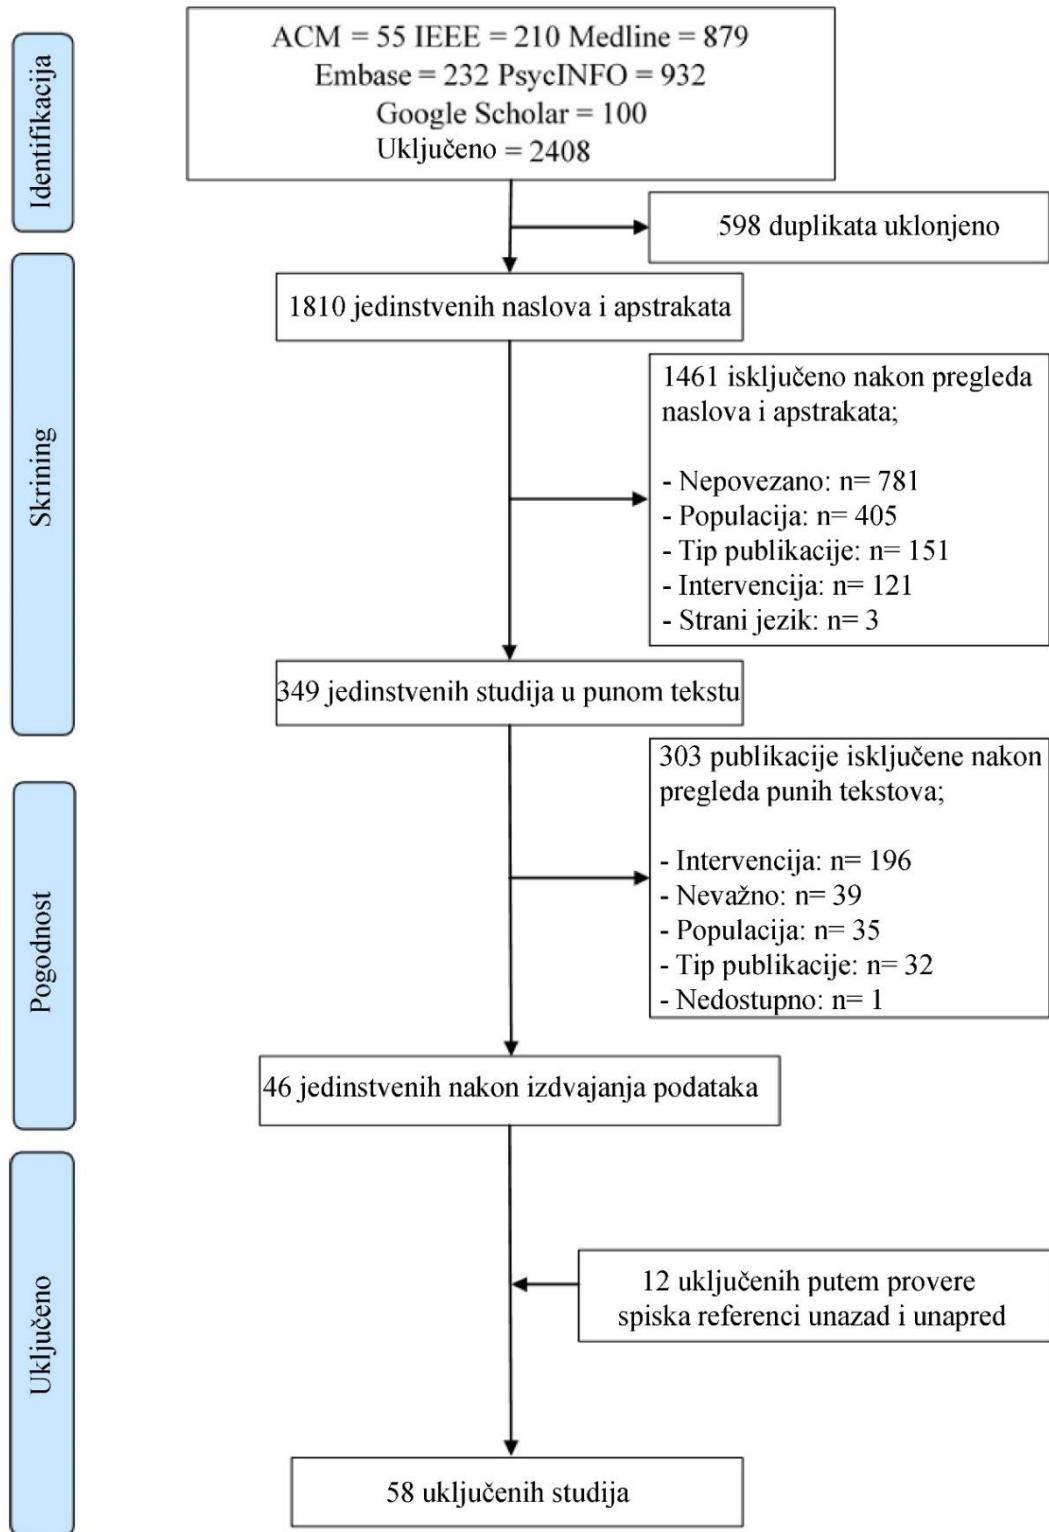
udruženja koledža. Štaviše, korišćenjem e-zdravstva, anksioznost mlađih ljudi je otkrivena bolje za oko 4,5% u poređenju sa prethodnim studijama [99]. Nalazi istraživanja potvrđuju da je postojanje servisa e-zdravstva kao i m-zdravstva povećalo nivo fizičke aktivnosti među mladima i motivisalo ih za obavljanje fizičkih aktivnosti [98].

Prethodna istraživanja koja su sprovedena u Sjedinjenim Državama tvrdila su da nisu postojali tačni i sveobuhvatni podaci o upotrebi nosivih uređaja. Jedno od istraživanja o usvajanju nosivih tehnologija sprovedeno je nad podacima iz 2019. i 2020. godine iz Nacionalnog istraživanja o trendovima u zdravstvu (*HINTS*). Istraživači su zaključili od 2.021 odraslih pacijenata, 85,9% njih se složilo da podele svoje podatke o mentalnom zdravlju prikupljene putem nosivih i pametnih uređaja sa zdravstvenim ustanovama [101].

Nakon pandemije *COVID-19*, rezultati poremećaja mentalnog zdravlja kao što je anksioznost pokazuju visoku stopu rasta. Korišćenje nosivih uređaja među pojedincima se povećava za bolničke i kliničke postavke [102].

Prethodni tekst imao je za cilj analizu faktora nosivih uređaja koji se mogu koristiti za otkrivanje i predviđanje anksioznosti. Detaljnu sistematsku analizu literature u oblasti primene nosivih uređaja za praćenje anksioznosti i depresije sproveli su Ahmed i koautori 2023. godine [102]. Oni su koristili šest bibliografskih baza podataka, uključujući *EMBASE*, *MEDLINE*, *IEEE Explore*, *PsicINFO*, *Google Scholar* i *ACM* digitalnu biblioteku [102]. U svom preglednom radu, procenili su 58 studija od ukupno 2408 značajnih rezultata. Analizirani su uređaji koji se nose na zglobu, poput pametnih narukvica. Državni popis osobina anksioznosti zajedno sa 26 istraživačkih metoda za analizu raspoloženja takođe je korišćen u tom istraživanju. Sve u svemu, 46% istraživačkih radova bavilo se pametnim telefonom kao pametnim nosivim uređajem. Slika 6 prikazuje proceduru sprovedenog istraživanja, gde je 598 radova isključeno kao duplikati, a 1810 naslova i apstrakata razmotreno u daljoj analizi. Tokom studije sa punim tekstrom, 303 istraživačka rada su isključena nakon pregleda punih tekstova, a na kraju je izabrano 46 jedinstvenih studija, dopunjeno sa još 12 studija nakon provere referenci [102].

Prema rezultatima, *Fitbit* (2009. godine) i *Apple Watch* (2015. godine) bili su rani razvijeni proizvodi, tako da su druge kompanije sledile taj put. Konačno, kombinovali su kliničke stručnjake i stručnost tehnologa na temelju nosivih uređaja za analizu anksioznosti i depresije među pojedincima [102]. Ovo pregledno istraživanje predstavlja dobru osnovu za dalja istraživanja u oblasti primene nosivih uređaja za detekciju i praćenje anksioznosti.



Slika 6. Dijagram toka analize literature za primenu nosivih uređaja kod anksioznosti i depresije [102].

Pored gore navedenih definicija, istraživači su istraživali povezanost anksioznih poremećaja sa srčanim ritmom koji je meren korišćenjem nosivih uređaja. Tomasi i koautori su 2024. godine adresirali izazove između varijabilnosti srčanog ritma i anksioznih poremećaja [103]. Istraživanje se fokusiralo na korišćenje nosivih uređaja i dizajna daljinskih studija za ponovnu analizu i procenu odnosa između varijabilnosti srčanog ritma i anksioznih poremećaja, kao i osobina povezanih sa anksioznošću. U tu svrhu, koristili su 240 učesnika (120 u kontrolnoj grupi o 120 sa anksionim poremećajem), a procene su obavljene u njihovim domovima korišćenjem pametnih uređaja poput narukvica za merenje varijabilnosti otkucanja srca. Učesnici su posebno izabrani iz istočne Azije, Afrike i Evrope, a što se tiče rezultata, samo starost je imala značajnu povezanost sa varijabilnošću srčanog ritma. Ovaj istraživački eksperiment pokazao je da se primenom nosivih uređaja može smanjiti varijabilnost otkucanja srca među pacijentima sa anksionim poremećajima [103].

Konačno, uvedene su različite i druge nove tehnologije koje su imale prihvativ uticaj na merenje, predviđanje i otkrivanje anksioznosti pojedinaca. Nosive tehnologije često se dopunjavaju primenom metoda veštačke inteligencije, naročito za pomoć u dijagnostici i predviđanje. Tehnologija mašinskog učenja poznata je kao jedan od najboljih pristupa kod predviđanja ili otkrivanja stresa i anksioznosti [33], što je detaljno predstavljeno u nastavku.

## 2.4. Mašinsko učenje i algoritmi u predviđanju stresa i anksioznosti

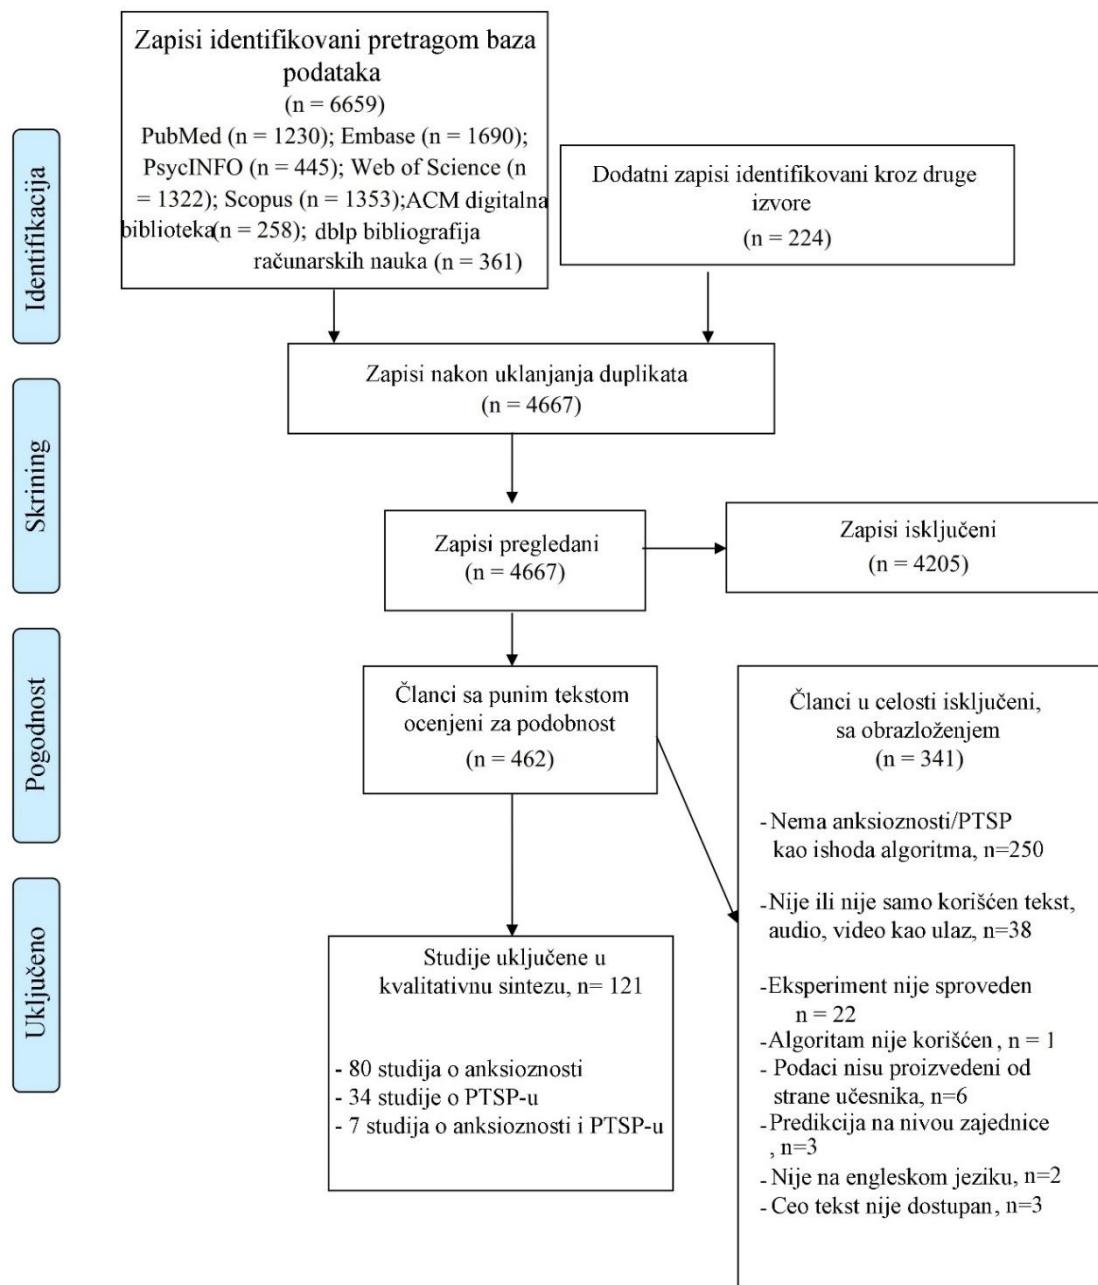
Predviđanje anksioznosti i stresa upotrebom mašinskog učenja povećano je zbog njegove tačnosti i visoke osetljivosti u realnom vremenu [6]. Kao što je spomenuto u prethodnim studijama, analiza podataka o anksioznosti u kontekstu mašinskog učenja može biti vrlo ekonomična [104], [105]. Takođe, tehnologije i metode mašinskog učenja mogu da analiziraju prilično složene podatke o stresu i anksioznosti [106]. Danas je upotreba mašinskog učenja za predviđanje anksioznosti sa velikom tačnošću uspela da poboljša performanse stručnjaka u tom pogledu.

Kao metode, multivarijaciona analiza i logistička regresija dale su prihvativije rezultate. U studiji Rihtera i koautora, podaci su analizirani sa šest kognitivno-bihevioralnih zadataka. Predviđanje anksioznih poremećaja zasnovano na mašinskom učenju pokazalo je 76,81% specifičnosti sa 69,66% osetljivosti među 25 osoba bez psihijatrijske dijagnoze [21]. Dakle, najvažnija tačka ovog istraživanja je povećanje poverenja između pacijenta i lekara kako bi se postigla prihvativija preciznost i individualno prilagođena terapija [21].

Nedavno su rezultati istraživanja pokazali da je predviđanje stresa i anksioznosti među studentima korišćenjem *support vector machine (SVM)* metode pokazalo bolje performanse u klasifikaciji mentalnih bolesti od drugih algoritama mašinskog učenja [107]. U tu svrhu i za određivanje stresa i anksioznosti, autori su koristili 29 istraživačkih studija u svom sistematskom pregledu iz 7 baza podataka, tako da su identifikovali 43 psihološke karakteristike, 15 demografskih karakteristika i neke socio-ekonomske, ekološke, akademske i druge karakteristike.

U današnjem umreženom svetu, algoritmi mašinskog učenja zasnovani su na audio, tekstualnim i video podacima u predviđanju stresa i anksioznosti. Njihova primena u kliničkoj i opštoj populaciji može poboljšati zadovoljstvo mentalnih pacijenata. Ciharova i koautori u svom istraživanju su spomenuli da tehnologija mašinskog učenja koristi prirodno ponašanje (video, audio i tekstualne podatke) i da takve tehnike mogu doprineti personalizaciji u psihologiji [108].

Ciharova i koautori su u svom sistematskom pregledu literature iz 2023. koristili pet baza podataka iz psihologije i dve baze podataka iz informacionih tehnologija. Analiza je zasnovana na radovima iz baza podataka kao što su *PubMed*, *Embase*, *APA Psycinfo*, *ACM* digitalna biblioteka, *Dblp*, *Scopus*) [108]. Na kraju, studija je obuhvatila detaljnu analizu 128 istraživanja, većinom objavljenih u Aziji i Severnoj Americi, a koja su u vezi sa primenama mašinskog učenja u kontekstu anksioznosti i posttraumatskog stresa. Slika 7 prikazuje metodološki postupan ove analize. Predviđanje anksioznosti i posttraumatskog stresa sprovedeno je radi poboljšanja standardizacije metoda, istraživanja u obe kliničke populacije i izveštavanja o rezultatima i preporukama za buduća istraživanja (Slika 7). Metode i algoritmi mašinskog učenja za predviđanje anksioznosti i posttraumatskog stresa bili su fokusirani na identifikaciju faktora za otkrivanje i predviđanje, ili čak poboljšanje prediktivne snage postojećih modela [108]. Predviđanje stresa i anksioznosti pomoću funkcija mašinskog učenja i algoritma baziranog na prirodnom ponašanju rezultira potencijalnim doprinosom za praćenje anksioznih poremećaja. Algoritmi mašinskog učenja kao što su regresija, neuralne mreže, ili *SVM* u tom pogledu uspevaju da predvide stres i anksioznost.



Slika 7. Komponente sistematskog pregleda literature o predviđanju anksioznosti na osnovu zvuka, teksta i videa pomoći tehnologije mašinskog učenja među kliničkom i opštom populacijom [108].

S druge strane, anksioznost studenata iz Saudijske Arabije (N= 3017) merenjem putem SVM-a postigla je tačnost od 100% [107].

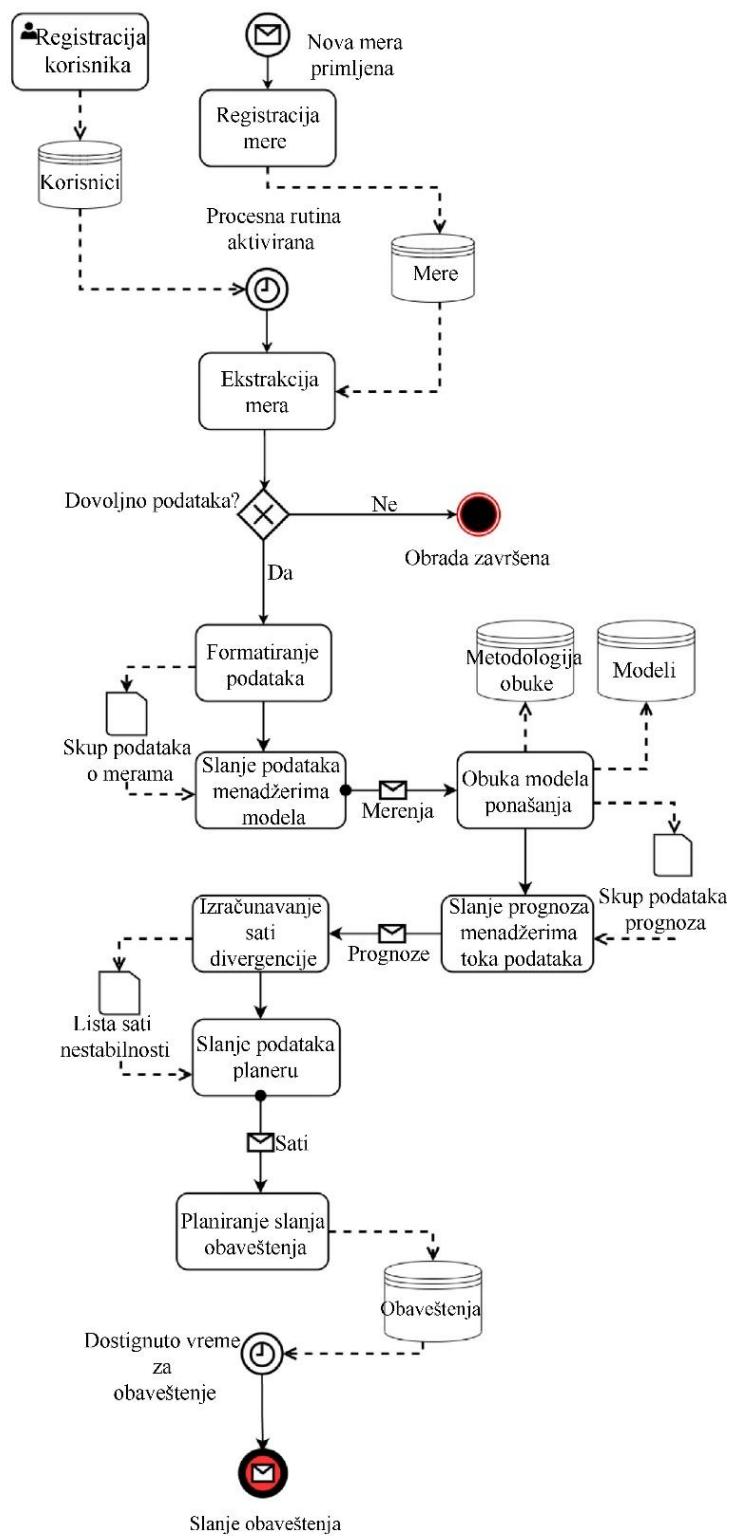
Fizička aktivnost kao plivanje, bicikлизам, i ostale slične aktivnosti su među vitalnim faktorima u smanjenju stresa i anksioznosti, dok u isto vreme jačaju zdravlje i fizičku snagu [109]. U Americi, metode dubokog učenja (eng. *Deep Learning - DL*) zasnovane na podacima sa mobilnih prenosivih uređaja mogu da predvide pojačavanje anksioznosti među mладим

ljudima sa prihvatljivim stepenom tačnosti (osetljivost=84.6%, tačnost=68.7%, i AUC=0.696, CI [0.598, 0.793]) [105]. Modeli dubokog učenja omogućili su bolju detekciju anksioznosti u populaciji između 17-18 godina, na osnovu navika spavanja i fizičke aktivnosti tokom dana.

Štaviše, podaci dobijeni iz telefonskog intervjuia pokazali su povećanje anksioznih poremećaja među 265 učesnika [105]. Povratna informacija dobijena iz rezultata analize omogućila je primenu tehnika mašinskog učenja u oblasti anksioznosti, uključujući razvoj novih algoritama, modela i metoda za praćenje anksioznosti.

Istraživači su otkrili da vremenom fizički izazovi, iscrpljujuća rutina, i radni sati mogu da imaju negativan uticaj na stres i anksioznost studenata. Bili su u mogućnosti da unaprede dobrobit u savremenom obrazovanju koristeći e-zdravstvo za praćenje i detekciju stresa i anksioznosti, oslanjajući se na algoritme mašinskog učenja. Sergio i koautori su u svom radu iz 2024. godine tvrdili da distribucija važnih podataka putem interneta i interneta inteligentnih uređaja, uz infrastrukturu zasnovanu na *cloud*, *fog* i *edge* komponentama, igra značajnu ulogu u e-zdravstvu za otkrivanje i predviđanje stresa i anksioznosti kod studenata. Oni su skupili podatke sa agenata na pametnim nosivim uređajima i sa senzora u kontekstu interneta inteligentnih uređaja, sa modelom predviđanja za svaki slučaj edukativnog agenta. *Fog*, *edge* i *cloud* komponente se odnose na predloženu arhitekturu sistema. Kao nastavak na ove definicije [110] Sergio i ostali predložili su komponente za njihov glavni model, uključujući "model detekcije ponašanja", "dizajn implementacije" i "eksperimentiranje" [110].

- **Model detekcije ponašanja:** Nakon istraživanja literature, otkrili su da korišćenje algoritama i funkcija mašinskog učenja može identifikovati modele i obrasce u ponašanju skupa podataka.
- **Dizajn implementacije:** Glavna infrastruktura je identifikovana nakon završetka modela i u tu svrhu su različite usluge proširene na željene funkcionalnosti.
- **Eksperimentisanje:** U tu svrhu, planirana je simulacija zasnovana na eksperimentu za izvršenje ovog sistema, kako bi se obrazovni softverski agenti mogli personalizovati na efikasan i automatski način [110].



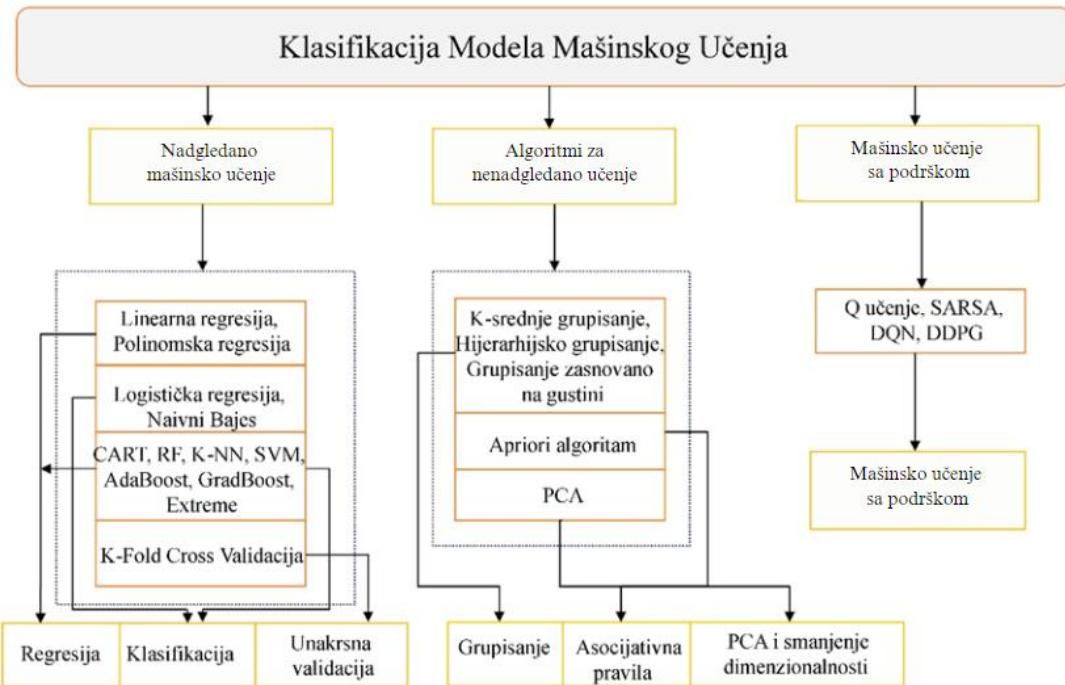
Slika 8. Dijagram toka podataka o poboljšanju zdravlja u savremenom obrazovanju sa predlogom servisa e-zdravstva za upravljanje stresom i anksioznošću na osnovu mašinskog učenja [110].

Zahvaljujući Slici 8, u ovoj prezentovanoj i razvijenoj arhitekturi, navedene funkcionalnosti i karakteristike, opisale su rad implementiranog obrasca i definisale njegovo ponašanje. U početku, sistem je proveren da bi se izbeglo preopterećenje i obezbedili efektivni obrasci ponašanja. Nakon standardizacije skupa podataka, započeta je obuka novog modela ponašanja sistema sa dovoljnim brojem merenja. Nakon testiranja različitih izvršavanja toka, utvrđeno je manje od trideset važećih merenja. Podaci iz skupa se zatim koriste od strane glavnog menadžera modela za testiranje i obuku modela mašinskog učenja. Ovaj proces generiše nekoliko nivoa, kao što su metrika obuke, specifikacije modela i predviđanja primljenih merenja. Ova predviđanja se šalju nazad u tok podataka da izračunaju razliku između skorih merenja i predviđanja. Tako su upoređena dva seta merenja sa servisom za upravljanje protokom podataka, a rezultati su prikazali razlike između trenutnih vitalnih znakova i procenjenih vitalnih znakova prema obrascu. Na kraju je kreiran servis za zakazivanje i lista vremena koju je softverski agent poslao tom servisu (Slika 8) [110].

Takođe, neke psihološke teme kao što je anksioznost dijagnostikovane su kroz obradu slike i algoritme dubokog učenja, u kom slučaju se bolest može preciznije kontrolisati [111]. Na primer, u automatskoj dijagnozi anksioznosti, zdravstveni prediktivni model, sa 510 pacijenata, potvrđen je algoritmima mašinskog učenja i postigao je tačnost predviđanja od 89% primenom *Random Forest* metode [6].

U 2024. godini sproveden je sveobuhvatan pregled analitičkih modela za detekciju i predikciju anksioznosti korišćenjem algoritama i funkcija mašinskog učenja. Monirul Islam i koautori su analizirali modele, algoritme i funkcije mašinskog učenja za rano otkrivanje mentalnih bolesti kao što je anksioznost. Oni su takođe tvrdili da praćenje društvenih medija može imati pozitivan uticaj na procenu mentalnog zdravlja, pružajući brzinu i tačan metod za otkrivanje i predviđanje stanja mentalnog zdravlja. Ovo istraživanje je dalo pregled modela mašinskog učenja i aplikacija za rano otkrivanje stresa i anksioznosti, posebno naglašavajući modalitete podataka. Rešen je problem praćenja društvenih medija putem verbalnih anketa, individualizovane podrške i nosivih uređaja. Ovaj sveobuhvatni pregled zasnovan na otkrivanju i predviđanju stresa i anksioznosti pomoću mašinskog učenja razvio je tačnu metodu za otkrivanje i predviđanje stresa i anksioznosti pojedinaca koji pomažu u dijagnozi takvih mentalnih bolesti [112].

Tri glavna tipa algoritama mašinskog učenja analizirana su i obrađena u studiji [112], uključujući nadgledano (eng. *Supervised ML*), nenadgledano (eng. *Unsupervised ML*) i mašinsko učenje sa podrškom (eng. *Reinforcement learning*). Uz regresiju i klasifikaciju iz nadgledanog algoritma učenja, neki problemi su rešeni korišćenjem označenog skupa podataka. U nenadgledanom učenju, detekcija i predikcija se ne vrše, i označeni skup podataka nije bio potreban. Umesto toga, mašina identificuje skrivene slične grupe unutar podataka, otkrivajući različite klastere. Ova metodologija postala je korisna za zadatke kao što su funkcionalna povezanost mozga i Alchajmerova bolest. Učenje na osnovu pojačanja proučavano je i korišćeno u robotima, raznim AI igrama i automobilima sa autonomnom vožnjom (Slika 9) [112].



Slika 9. Klasifikacija i primenjena polja modela mašinskog učenja [112].

Autori su predstavili hipotetičko poređenje postojećih alata koristeći standarde u nastavku i predloženu metodu koja uključuje: tačnost, efikasnost, pristupačnost, korisničko iskustvo, dugoročno praćenje. U osnovi, pristup mašinskog učenja za rano otkrivanje i predviđanje mentalnih bolesti poput stresa i anksioznosti pružio je originalne eksperimentalne rezultate u tom pogledu. Takođe je uveden višestruki domen podataka svakog uzorka podataka (pojedinaca) kako bi se osiguralo konačno otkrivanje i predviđanje [112].

Žene starosti između 18 i 35 godina pate od anksioznih poremećaja više nego muškarci, prema studiji Svetske zdravstvene organizacije (SZO). Podaci o anksioznosti prikupljeni su putem standardnog upitnika sa 35 pitanja među pacijentima iz medicinske bolnice Dhaka i Medicinskog koledža Rangpur u Bangladešu. Konvolucionna neuronska mreža (CNN) korišćena je za dijagnostikovanje anksioznosti tako da su rezultati bili zasnovani na različitim kriterijumima merenja, CNN algoritam je imao najpovoljniji efekat sa tačnošću od 96% [19].

S jedne strane, detekcija anksioznosti među studentima univerziteta putem algoritama mašinskog učenja je proširena. Na primer, istraživanje provedeno među 127 studenata inženjerstva u Indiji dalo je rezultat sa tačnošću od 78,9%. Ova istraživanja koristila su 40 pitanja putem upitnika kako bi analizirala anksioznost indijskih studenata, sa kategorijama demografskih podataka, verovatnih uzroka anksioznosti i verovatnih efekata anksioznosti. Jedan od ciljeva ovog istraživanja bio je da se prepozna rizik od teškog mentalnog sloma [113].

Nedovoljna pažnja posvećuje se značajnom pitanju u upravljanju anksioznošću, posebno među mlađim uzrastima, što dovodi do potencijalno nesigurnih posledica. Algoritmi

mašinskog učenja sa 80% tačnosti i 93% osetljivosti, koristeći audio podatke, bili su u stanju da predvide anksioznost u detinjstvu [3]. Utvrđeno je da deca koja su pogodjena anksioznošću govore niskim glasovima i sa devijacijom. Takođe, rezultati sistema pokazali su da deca i tinejdžeri doživljavaju veći stres u kliničkim okruženjima [3].

Pored toga, prema [114], većina studenata koji pate od stresa i anksioznosti ne mogu da shvate takvu mentalnu bolest. Ovi autori su prikupili podatke o studentskim mentalnim bolestima kao što je stres i anksioznost putem standardnog upitnika koji uključuje 21 pitanje, i analizira podatke koristeći pet algoritama mašinskog učenja kao što je *random forest*, drvo odlučivanja, logistička regresija, K-najbližih suseda i *Naive Bayes*. Algoritam K-najbližih suseda pokazao je najbolju izvedbu sa preciznošću od 0,972, F1-score-om od 0,932 i tačnošću od 0,935%. Ovaj algoritam je takođe pokazao najbolju izvedbu u vezi sa stresom, pri čemu su postignuti rezultati preciznosti = 0,984, F1-score = 0,988 i tačnost od 0,992% [114]. Drugo istraživanje izvestilo je o podacima anksioznosti izvučenim iz *STAI* upitnika i analiziralo ih pomoću linearne regresije [77]. Linearni regresioni algoritam je korišćen za istraživanje u ovoj doktorskoj disertaciji.

Tokom pandemije *COVID-19* u Indiji, većina ljudi je podelila svoja mišljenja o anksioznosti u onlajn kontekstu, o čemu je Svetska zdravstvena organizacija (*SZO*) izvestila u martu 2020. godine. Pored toga, u Indiji je 840.000 tвитова korišćeno za otkrivanje anksioznosti pomoću algoritama mašinskog učenja sa visokom tačnošću [115]. Štaviše, mašinsko učenje je takođe pokazalo različite nivoje generalizovane anksioznosti klasifikovane korišćenjem podataka 3017 učesnika, tako da je klasifikacija sa algoritmom stabla odlučivanja pokazala tačnost od 100% [116].

Zapravo, rezultati istraživanja su pokazali da su klasifikatori mašinskog učenja delovali kao glavni pristup razdvajanju ponašanja stresa i anksioznosti [117]. U današnjem svetu komunikacije, poboljšane su performanse ML-a za otkrivanje anksioznosti. Na primer, anksiozni poremećaji su uočeni putem društvenih medija kao što su *Facebook* i *X* [77], [118]. Mašinsko učenje je uspelo da otkrije anksioznost kroz ukupne podatke na različitim društvenim medijima [118], [119].

Nalazi istraživanja potvrđuju da se greške u procesu detekcije anksioznosti upotreboom veštačkih neuronskih mreža (*ANN*) mogu smanjiti [120], a jaka baza podataka igra vitalnu ulogu u tom pogledu [121]. Pored toga, prethodna studija je podatke stavila u algoritam za ekstrakciju vokalnih funkcija tako da su eksperimenti koji su koristili *random forest* algoritam pokazali performanse sa 75,27% tačnosti [122].

## 2.5. Izazovi predviđanja anksioznosti primenom mašinskog učenja

Tehnologija mašinskog učenja napravila je značajnu promenu u predviđanju anksioznosti studenata [18], [34]. Sažetak relevantnih istraživanja u oblasti predviđanja anksioznosti i stresa zasnovanih na servisima e-zdravstva i primeni mašinskog učenja, uključujući nalaze i koristi, prikazan je u Tabeli 2.

*Tabela 2. Istraživanja u oblasti predviđanja anksioznosti putem mašinskog učenja.*

Ne.	Autorov Naziv	Izazovi ili ograničenja	Fokus → cilj
1	[Gruda and Hasan, 2019], [77]	Generalno kratak tekst i pogrešno napisane reči.	Cilj predviđanja budućih ishoda, kao što su popularnost i društveni angažman.
2	[Richter et al., 2021], [21]	Većina učesnika su bile žene, zbog čega nije bilo rodne ravnoteže.	Analiza koja se fokusira na anksioznost kako bi se napravila razlika između kliničke anksioznosti i poremećaja depresije.
3	[Garcia-Chimeno et al., 2017], [123]	Nije bilo velikog broja uzoraka za skup podataka.	Fokusiranje na patologije migrene i slike magnetne rezonance radi automatizacije dijagnoze.
4	[Eeden et al., 2021], [124]	Neke razlike između DSM-IV-TR (Vrsta mentalnih poremećaja) i DSM-5 (Alat za kliničku dijagnozu mentalnog zdravlja) za anksioznost i nekih dijagnostičkih algoritama koji su korišćeni u ovoj studiji su malo zastareli.	Korišćenje algoritama mašinskog učenja za predviđanje početka anksioznosti.
5	[Sharma and Verbeke, 2021], [125]	Izazovi: zbog malog uzorka podataka, predviđanje anksioznosti ljudi bilo je prilično teško. Ograničenja: istraživački fondovi su bili ograničeni, a baza podataka imala je određena ograničenja u pogledu broja biomarkera.	Ovo istraživanje je fokusirano na građane Holandije (veličina uzorka 11081) kako bi se izdvojili tipovi anksioznog poremećaja.
6	[Demiris et al., 2020], [126]	Izazovi anksioznosti koju pacijenti sami prijavljuju. Ograničenje se odnosilo na skup podataka za obuku.	Cilj ovog istraživanja bio je da se ekstrahuju karakteristike transkribovanih audio komunikacionih podataka ekstrahovanih korišćenjem mašinskog učenja.
7	[McGinnis et al., 2019], [127]	Izazovi i ograničenja su se fokusirali na ogroman skup podataka koji je ispitivao poremećaje internalizacije.	Ova studija je koristila tehnike mašinskog učenja za poboljšanje anksioznosti u detinjstvu koja je tek počela.
8	[Ihmig et al., 2020], [128]	Ova studija ima određene izazove prilikom prikupljanja podataka, pa su zbog toga tri zapisa zanemarena.	Važan fokus ove studije bio je ispitivanje HRV – varijabilnosti srčane frekvencije – biofeedback intervencije u terapiji. Cilj ovog istraživanja bio je

			korišćenje fizioloških odgovora za predviđanje anksioznosti.
9	[McGinnis et al., 2018], [129]	Postojala su neka ograničenja dok su klinike prikupljale izveštaje od roditelja, dece i nastavnika.	Smanjenje vremena dijagnoze, fokus na mentalno blagostanje.
10	[Masino et al., 2019], [130]	Fiziološke mere.	Sprečavanje pogoršanja ponašanja.
11	[Labus et al., 2021], [8]	Prikupljanje podataka iz stomatologije.	Upravljanje anksioznošću i stresom do opuštanja umu i smanjenja fizičke napetosti u stomatologiji.
12	[Bokma et al., 2020], [74]	Predviđanje anksioznih poremećaja nije bilo dostupno.	Pružanje individualnih predviđanja perioda bolesti.
13	[Priya et al., 2020], [33]	Prikupljanje podataka od zaposlenih i nezaposlenih pojedinaca u različitim kulturama.	Poboljšanje predviđanja problema sa stresom i anksioznošću.
14	[Nemesure et al., 2021], [131]	Postojalo je nekoliko ograničenja u vezi sa skupom podataka francuskih studenata, veličinom uzorka i sličnim faktorima.	Pomoći u identifikaciji prediktora velikog depresivnog poremećaja i generalizovanog anksioznog poremećaja za njihovo rano otkrivanje.
15	[Sau and Bhakta, 2019], [111]	Proučavanje teškog slučaja.	Periodični skrining za anksioznost pomoraca koji koristi tehnologiju mašinskog učenja kao brzu i automatizovanu proceduru skrininga za identifikaciju rizičnih pomoraca.
16	[Daza, et al., 2023], [107]	Faktori koji zbunjuju, posebno skeniranje i pol. Otkrivanje takvih bolesti tokom COVID-19 takođe je bilo jedno od ograničenja i izazova.	Bolje razumevanje karakteristika i analiza takvih karakteristika stresa i anksioznosti studenata korišćenjem algoritama i funkcija mašinskog učenja.
17	[Schiavo et al., 2024], [132]	Uopštenost nalaza postala je ograničena zbog sastava uzorka.	Fokusiranje na AI aplikacije i upitnik su se među većinom faktora odnosili na veštačku inteligenciju, što je povećalo varijabilnost rezultata. Povećanje uočene korisnosti i lakoće korišćenja za prihvatanje stavova pojedinaca prema veštačkoj inteligenciji.

Reakcija u realnom vremenu može se dogoditi korišćenjem nosive tehnologije i uspela je da otkrije i spreči neke poremećaje sa predstojećim stresom i anksioznošću. Važni izazovi predviđanja anksioznosti korišćenjem novih metoda poput mašinskog učenja uključuju prikupljanje podataka, ograničen broj učesnika, a ponekad i studiju o prilično teškom slučaju. Jedan od aktuelnih ciljeva istraživanja bio je rešavanje ovakvih problema.

Studije u Kanadi su pokazale da akumuliranje više fizičke aktivnosti ljudskog bića može smanjiti anksioznost [133], [134]. Pored ovih razloga, rezultati istraživanja u Nemačkoj pokazali su da su studenti koji su imali anksioznost verovatnije pušili [42].

## 2.6. Pregled literature o otkrivanju anksioznosti kod mladih ili studenata korišćenjem mašinskog učenja

Poremećaji mentalnog zdravlja kao što je anksioznost povećana je među mladim ljudima. Anksioznost se može otkriti pažljivo koristeći mašinsko učenje i odgovarajuće uređaje kao što su medicinski senzori [135], [136]. Pored toga, identifikovanje ključnih faktora povezanih sa anksioznosću mladih odraslih osoba koje su imale 19 godina korišćenjem *support vector machine* (F1-score od 89,7%), koje su izvučene iz *Q-Life* aplikacije, pokazalo je da nedostatak motivacije može izazvati anksioznost.

Međutim, sažetak pregleda literature o detekciji anksioznosti kod mladih ili studenata korišćenjem tehnologije mašinskog učenja, uključujući njegovu svrhu, metodologiju, nalaze i ograničenja, prikazan je u Tabeli 3.

Tabela 3. Pregled istraživanja o otkrivanju anksioznosti mladih ili studenata korišćenjem mašinskog učenja.

Autor(i) Citat	Cilj	Metodologija	Nalazi	Ograničenja
[138]	Godine kao glavni činilac kod predviđanja stresa i anksioznosti.	Razvoj osam mašina za učenje prediktivnih modela koristeći algoritmi nadgledanja i od klasifikacije i regresije.	Poboljšanje kreiranja politika unutar oblasti obrazovanja i podizanje svijesti u vezi mentalnog zdravlja.	Studija preseka je bila pod uticajem zbunjujuće pristrasnosti kao pre-pandemično mentalno stanje i iskustva sa nasiljem.
[13]	Da identificuje mentalne bolesti i probleme učenika, kao i ograničenja anksioznosti i izazove u učionici.	Istraživači su prikupili podatke iz četiri baze podataka: Google Scholar, Microsoft Academic, Science Direct i PubMed. Ovo istraživanje je koristilo tehnike prepoznavanja obrazaca i statističke alate. U osnovi, fiziološki signali su spojeni sa klasifikacionim algoritmima.	Fiziološki signali su pokazali smanjeno vreme odgovora, a otkrivanje anksioznosti među studentima je bilo ohrabrujuće.	U istraživanju je nedostajala mala veličina uzorka i merenje bio-signala u učionici.
[35]	Predvideti faktore rizika od anksioznosti među studentima primenom mašinskog učenja.	Ovo istraživanje je sprovedeno pomoću upitnika, među 3984 učenika, uzrasta 10 – 15 godina, u periodu od 2013. do 2014. školske godine. Rezultati su dobijeni korišćenjem algoritama nadgledanog	Nalazi su pokazali da SVM modeli (92,4% tačnosti) i <i>random forest</i> (78,6% tačnosti) imaju visoku tačnost za anksioznost. Pored toga, ovo istraživanje je pokazalo da su porodični prihodi,	Izdvajanje ponašanja učenika u školi, aktivnosti na društvenim mrežama i društvene aktivnosti bile su neka od ograničenja ove studije.

		učenja.	akademski uspeh i školsko nasilje i maltretiranje bili najznačajniji faktori koji utiču na anksioznost učenika.	
[139]	Dobijanje korisnih informacija o anksioznosti imalo je prilično negativan uticaj na studije studenata.	Korišćenje SVM kao jednog od algoritama mašinskog učenja u tehnologiji statističkog učenja pomoću MATLAB programskog jezika.	Reakcija studenata je analizirana ogromnom količinom informacija, pa je to filtrirano kroz model optimizacije.	Bilo je određenih poteškoća u prikupljanju različitih vrsta informacija o anksioznosti učenika u školi.
[140]	Ovo istraživanje je primenilo regresiju obrasca za predviđanje simptoma anksioznosti od normalnog do patološkog nivoa.	Uzorak je bio sastavljen od 154 mlade odrasle osobe tako da je srednja starost bila 21 godina, a 103 osobe su bile žene. Regresija Gausovog procesa (GPR) i analize regresije uzorka korišćene su za ovo istraživanje, a za procenu performansi modela korišćen je MSE.	Identifikovani su obrasci neuronske aktivnosti da bi se predviđela anksioznost samoprocene. Dve vrste strategija validacije sa najvećom vrednošću MSE, a rezultati su pokazali MSE=4,47 (P-Value=0,001) i MSE=4,62 (P-Value=0,003).	Skener i pol bili su dva potencijalna zbunjujuća faktora povezana sa kliničkim rezultatima.
[141]	Ova studija se fokusirala na razvoj nomogramskog modela predviđanja za znakove anksioznosti među studentima medicine.	Prikupljene su dve grupe podataka učesnika, prva grupa je imala anksioznost među 126 osoba, a 774 učesnika bez simptoma anksioznosti analizirano je algoritmom logističke regresije.	Česta upotreba duvana i alkohola, nisko zadovoljstvo životom, nedostatak socijalne podrške i nisko subjektivno blagostanje bili su faktori koji su analizirani korišćenjem logističke regresije.	Različiti izvori simptoma anksioznosti studenata postdiplomskih studija medicine nisu bili dovoljni.
[142]	Primena algoritama mašinskog učenja nad rezultatima magnetne rezonance, za predviđanje poremećaja i analizu socijalne anksioznosti kod omladine.	Analizirane su slike sa magnetne rezonance u stanju mirovanja pomoću KSGBoost modela.	Nalazi istraživanja su pokazali potencijalnu validnost za socijalnu anksioznost predviđenu tako da je performansa tačnost sa 77,7%, kao i F1 skor od 0,815.	Uzorci podataka mladih odraslih učesnika nisu bili dovoljni za ovu studiju. Ostala ograničenja ovog istraživanja uključivala su nerazdvajanje pola ili starosti mladih odraslih osoba.
[143]	Razvijanje pouzdanog mašinskog učenja za poboljšanje modela za predviđanje percipiranog stresa	Analiziranje onlajn ankete 444 studenata univerziteta korišćenjem algoritma za nadzirano učenje, kao i genetskog algoritma i unakrsne	Približno 11,26 učesnika imalo je visok nivo socijalnog stresa, a oko 24,10% rezultata pokazalo je ekstremni stres sa 80,5% tačnosti	Postojao je nedostatak validacije kada su istraživači koristili stvarne podatke.

	među 444 studenta.	validacije pretrage mreže.	i 0,890 F1 skorom. Nalazi ovog istraživanja mogu se razviti smanjenjem štetnog uticaja na dobrobit učenika, kao i stresnih situacija.	
[144]	Da bi se predvidela anksioznost među studentima, cilj istraživanja je bio korišćenje metode sa četiri kombinovana modela zasnovana na Stackingu.	Skup podataka je prikupljen od studenata računarskog inženjerstva koji su bili studenti osnovnih studija na javnom univerzitetu. Algoritmi za nadzirano učenje analizirali su 284 skupa podataka učesnika.	Algoritam k-najbližih suseda koji koristi slaganje dobio je tačnost od 97,83%.	Upitnik za generalizovani anksiozni poremećaj bio je prvo ograničenje ovog istraživanja, takođe socijalno i socio-ekonomsko, a kao kritični izazovi i ograničenja pomenuta su pitanja životne sredine.
[145]	Prepoznavanje stresa, anksioznosti i depresije među studentima korišćenjem algoritama mašinskog učenja koji su primenjeni na upitnike, video i audio skupove podataka.	Nekoliko algoritama i funkcija korišćeno je u metodologiji za model prepoznavanja emocija.	Razmatranje kompetentnosti mašinskog učenja u otkrivanju stresa i anksioznih poremećaja. Za ovaj sistematski pregled literature prikazane su prednosti i nedostaci korišćenja modela zasnovanih na viziji.	Nedostatak hardverskih uređaja za identifikaciju aktivnosti stresa, anksioznosti i depresije i dizajniranje modela za analizu nivoa znakova stresa, anksioznosti i depresije.
[146]	Studija je imala za cilj da milione pojedinaca upozna sa ranim otkrivanjem i predviđanjem stresa.	Podaci o stresu su prikupljeni putem upitnika i sličnih informacija u vezi sa tim, i analizirani različitim algoritmima mašinskog i dubokog učenja.	Pronalaženje štetnih uticaja ili faktora na stres i anksioznost postignuto iz živopisnih konteksta zanimanja zbog radnih, psiholoških i ličnih razloga.	Liste za pregled i faktori koji se odnose na stres bili su ograničeni na učesnike (studente) i zaposlene.

Pored toga, donošenje odluka vođeno podacima (*eng. Data-Driven Decision-Making - DDDM*) predstavljalo je glavni nedostatak u jednoj od prethodnih studija, zbog nepoklapanja srednjih vrednosti skorova anksioznosti dobijenih različitim metodama [147]. Rezultati istraživanja u Severnoj Karolini tvrde da anksiozni poremećaji najviše štete onima koji su radili prekovremeno. Takođe, izveštaji o anksioznim poremećajima kod studentkinja pokazali su manju želju za pušenjem kada su se suočile sa anksioznošću [41]. Pored ovih faktora, upotreba alkohola i droga mogla bi uticati na simptome anksioznosti studenata, a tehnike mašinskog učenja otkrile su anksiozne poremećaje koristeći kliničke biomarkere u tom pogledu [125].

Dakle, jaz u literaturi (Tabela 3) bio je pristup odgovarajućoj veličini uzorka anksioznosti među studentkinjama univerziteta povezanim sa mašinskim učenjem. Štaviše, različiti izvori simptoma anksioznosti studenata navedeni su kao nedovoljni. Konačno, otkrivanje i predviđanje stresa i anksioznosti korišćenjem algoritama za nadgledanje učenja kao odgovarajućeg alata uzrokuje razvoj primenjivog pristupa. Programski jezik *Python* je takođe poznat kao jedan od najkorisnijih alata za implementaciju algoritama za otkrivanje i predviđanje stresa i anksioznosti studenata [116], [148].

### **3. Model ekosistema pametne zdravstvene zaštite za otkrivanje i predviđanje stresa studenata**

Pametni zdravstveni ekosistem se odnosi na integrirani obrazac ili sistem koji koristi moderne tehnologije kao što su internet inteligentnih uređaja, veštačku inteligenciju i analitiku podataka kako bi poboljšao praćenje, isporuku i upravljanje u zdravstvu.

Ovaj ekosistem obično uključuje zdravstvenu negu pacijenata, pružaoce usluga, istraživače, i administratore, svi zajedno su povezani međusobno kroz digitalne platforme. U višem obrazovanju, pametni zdravstveni ekosistem prilagođava zdravstveni pristup i nove tehnologije potrebama studenata u sklopu akademskih institucija. Takođe se fokusira na pružanje i poboljšanje personalizovane zdravstvene zaštite i rešenja za studente, koristeći pametne zdravstvene alatke i AI algoritme za nadgledanje.

Otkrivanje i predviđanje stresa i anksioznosti studenata u kontekstu pametne zdravstvene zaštite uključuje upotrebu senzora, pametnih nosivih uređaja ili digitalnih platformi za prikupljanje podataka o ponašanju studenata, kao i studentkinja. AI algoritmi i funkcije analiziraju takve podatke kako bi identifikovali obrasce stresa ili anksioznosti.

Veštačka inteligencija igra vitalnu ulogu u ovom obrascu tako što precizno i brzo obrađuje ogromne količine podataka. Algoritmi i funkcije mašinskog učenja mogu učiti iz podataka obrasce i prilagođavaju se tokom vremena kako bi se poboljšala tačnost detekcije i predviđanja stresa i anksioznosti.

Da bismo objasnili glavni obrazac ovog istraživanja (Slika 10), treba naglasiti da su studenti visokog obrazovanja izabrani kao ciljna grupa naše studije. Studentkinje su zatim odabране za drugi deo ove istraživačke analize. S obzirom na to da je u ovoj studiji navedeno da je *STAI* upitnik izabran iz rada Spielbergera i koautora [4], [149], [150], postavljena su dodatna korisna i relevantna pitanja u vezi sa stresom i anksioznošću studenata u upitniku. Nakon provere upitnika o stanju anksioznosti i relevantnih pitanja, deo predobrade podataka ušao je u naš obrazac. Dalje, izvukli smo samo skupove podataka o stresu studentkinja, zajedno s tri važne karakteristike, uključujući fizičku aktivnost, pušenje cigareta i njihovu prosečnu ocenu tokom studiranja, tako da su takvi vitalni faktori imali prilično značajan uticaj na stres i anksioznost studentkinja.

Linearni regresioni algoritam je kodiran u *Jupyterlabu* koristeći *Python* kodove. Za obuku je odvojeno 70% podataka i 30% podataka je korišćeno za testni deo. *MAE* i *MSE* su korišćeni za procenu stope greške našeg modela pomoću linearног regresionог algoritма, tako da je funkcija *LASSO* pokazala faktore među upitnicima sa najvećim uticajem na anksioznost stanja i anksioznost osobina. Zajedno sa *LASSO* funkcijom, koristili smo algoritam k-najbližih suseda da bismo prikazali situaciju sa treningom modela, a zatim pokazali nedovoljno prilagođavanje i prekvalifikaciju. Dakle, komparativna analiza rezultata dobijenih iz analize uporedila je algoritme i funkcije koje su kodirane, kao i pristup ove studije.

Pored funkcija greške kao što su srednja apsolutna greška i srednja kvadratna greška, za ovo smo koristili koren srednje kvadratne greške. U međuvremenu, klaster analiza podataka o

studentkinjama je metoda koja se koristi u našem obrascu. Ovaj algoritam mašinskog učenja namenjen grupi subjekata u istom klasteru implementiran je *k-means* klaster analizom. Štaviše, komparativna analiza je proverena posebno među skupovima podataka studentkinja kako bi se proverila konačna predviđanja sa intervencijom ključnih karakteristika i jednom bez intervencije vitalnih karakteristika.

U međuvremenu, *biofeedback* u kontekstu detekcije i predviđanja stresa i anksioznosti pomoću mašinskog učenja uključuje upotrebu fizioloških signala za procenu i praćenje nivoa stresa pojedinca. Ovaj deo procesa može koristiti različite algoritme mašinskog učenja da interpretira podatke i obezbedi vredan uvid u vezi sa stresom. Kanali koji mogu da se koriste da bi se pružila povratna informacija studentima i studentkinjama, uključuju platforme društvenih medija, *SMS* ili mejl obaveštenja, mobilne aplikacije, i slično, što se može koristiti u našim okvirima.

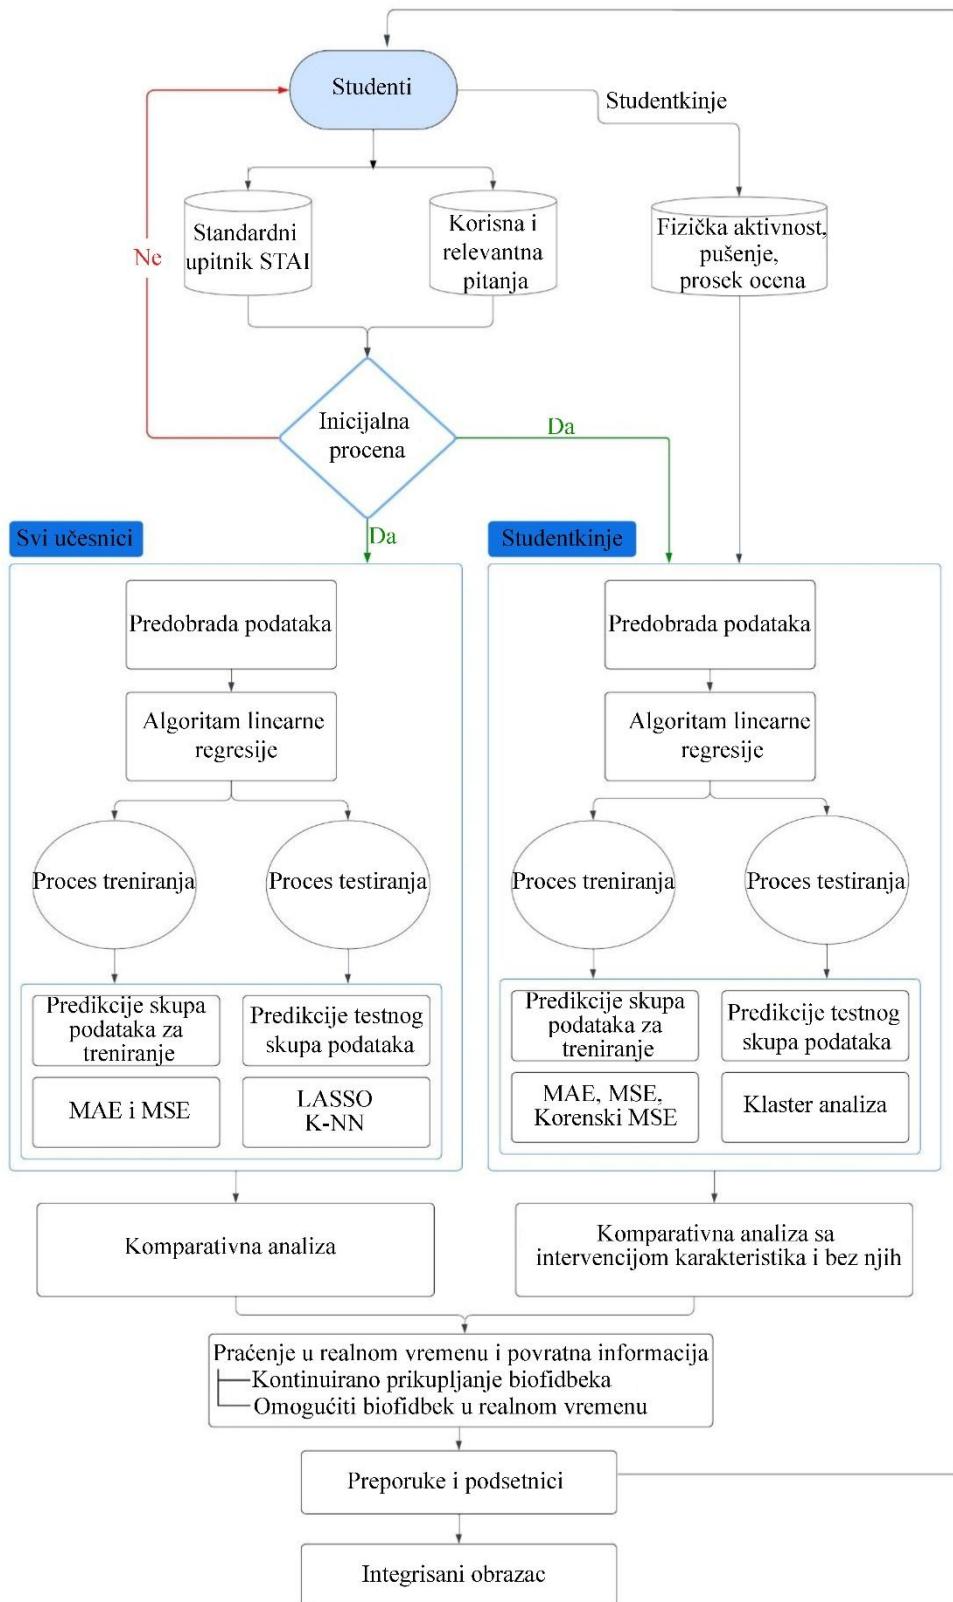
Ostali primeri uključuju razgovor sa studentima o stresu i anksioznosti putem pametnog telefona i izveštavanje o povratnim informacijama putem *Moodle* sistema za upravljanje učenjem, a mogu se predstaviti i automatizovane povratne informacije personalizacijom *Moodle* sadržaja.

Nakon dobijanja ovih uvida, korisnicima se mogu poslati personalizovane preporuke. To može uključivati predloge za vežbe disanja ili vežbe svesnosti prilagođene njihovim specifičnim potrebama i nivoima stresa. Štaviše, ove informacije se mogu integrisati u sveobuhvatan obrazac tako da se kontinuirano uči i prilagođava tokom vremena.

Ovaj dinamični obrazac može predvideti buduće stresne epizode i ponuditi proaktivne intervencije pre nego što nivoi stresa postanu nekontrolisani. Pored ove tačke, integracija *biofeedback-a* može poboljšati razvoj personalizovanih *velnes* programa. Kontinuiranom analizom, a zatim i praćenjem fizioloških podataka pojedinca, predloženi obrazac može usavršiti svoje preporuke i pružiti povratne informacije u stvarnom vremenu kako bi se studentima pomoglo da efikasnije upravljaju stresom.

Konačno, ova tehnologija ima potencijal da se integriše u nosive uređaje, čineći je dostupnom i pogodnom za svakodnevnu upotrebu. Kao aplikacija koja bi mogla biti kodirana za ovo istraživanje i koja će biti instalirana na pametnom telefonu, ona kontinuirano prikuplja podatke, pokreće ih kroz algoritme mašinskog učenja i pruža trenutne povratne informacije i preporuke.

Ova petlja *biofidbeka* u realnom vremenu može značajno poboljšati sposobnost studenta da upravlja stresom. Sve u svemu, istraživanje kombinacije tehnologije mašinskog učenja i *biofidbeka* predstavlja vitalni napredak u kontekstu zdravstvene zaštite zasnovane na podacima. Ne samo da nudi sofisticiranu metodu za otkrivanje i predviđanje stresa i anksioznosti, već i osnažuje studente sa praktičnim uvidima i alatima za preuzimanje kontrole nad stresom ili anksioznošću (Slika 10).



Slika 10. Glavni predloženi model zasnovan je na pametnom zdravstvenom ekosistemu za otkrivanje i predviđanje stresa studenata koristeći AI u visokom obrazovanju.

## 4. Metodološki postupak istraživanja

### 4.1. Istraživački okvir

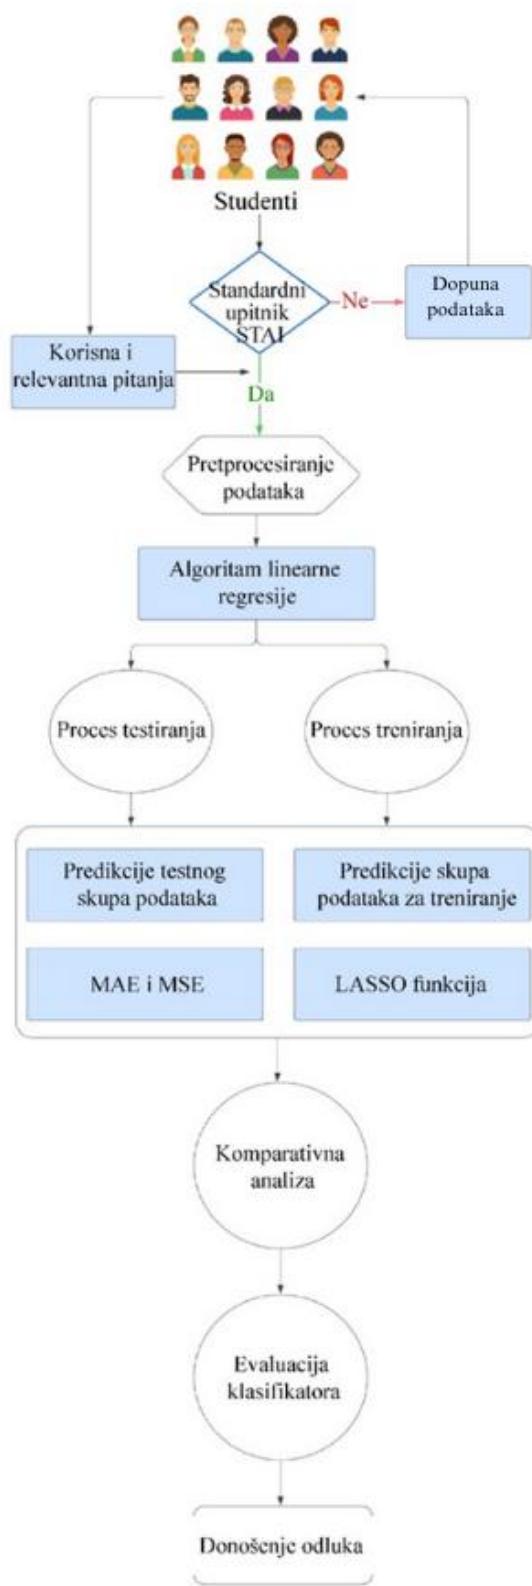
Ovo istraživanje analiziralo je i procenilo anksioznost studenata na Univerzitetu u Beogradu. Zbog pandemije *COVID-19*, većina kurseva na univerzitetu održana je u onlajn kontekstu. Za ovo istraživanje nismo bili u mogućnosti meriti anksioznost putem senzora i e-zdravlja, zbog čega smo se odlučili za procenu anksioznosti učenika putem standardnog upitnika koristeći algoritme mašinskog učenja. Kao takvo, ovo istraživanje upotpunjuje prethodnu studiju koja je tvrdila o praćenju anksioznosti među mladima koristeći algoritme mašinskog učenja [151]. Ova metodologija omogućava brzu procenu i analizu anksioznosti. Slika 11 prikazuje prvi istraživački pristup predviđanju anksioznosti učenika koristeći mašinsko učenje [111], [152].

U početku je istraživački pristup uključivao različite delove predviđanja anksioznosti studenata pomoću mašinskog učenja. Standardni upitnik *STAI-a* [**Dodatak A.**] i dodatna dva pitanja postavljena su kako bi se procenila upotreba modernih tehnologija od strane studenata (Tabela 9):

1. Koristite li mobilne aplikacije za zdravlje kao što je aplikacija za upravljanje anksioznošću na pametnom telefonu?
2. Da li želite da se vaša anksioznost predvidi korišćenjem mašinskog učenja?

Takođe, prethodna obrada podataka bila je drugi deo ovog pristupa u prvom delu istraživanja, i onda je skup podataka pripremljen da bude u linearnoj regresiji. U ovoj studiji, pristup linearnoj regresiji se bira na osnovu rezultata iz literature [77]. Pored toga, *MAE* i *MSE* su korišćene za odvajanje stanja i osobina anksioznosti [153].

Nakon koraka obuke, funkcija *LASSO* prikazuje karakteristike sa velikim uticajem na model [154]. Proces obuke je uticao na funkciju *LASSO-a*, a *MAE* i *MSE* faktori su postignuti i iz procesa obuke i iz procesa testiranja. Konačno, nakon izvlačenja tačnosti modela iz testnog i trening skupa podataka, u istraživačkom pristupu pominju se komparativna analiza, klasifikatorska evaluacija i donošenje odluka.



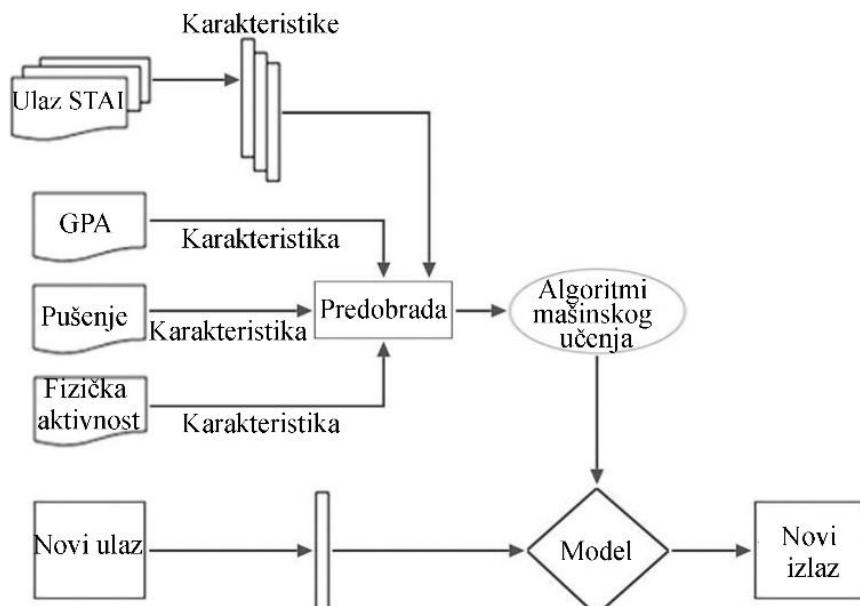
Slika 11. Istraživački pristup predviđanju anksioznosti učenika koristeći mašinsko učenje (anksioznost stanja i osobina među svim skupovima podataka učenika).

Sledeći deo ovog istraživanja odnosi se na predloženu metodologiju za otkrivanje stresa i anksioznosti kod studentkinja koristeći tehnike mašinskog učenja. Predložena metodologija istraživanja zasniva se na brzim algoritmima za analizu podataka [13], [18]. U početku se bira stanje anksioznosti da izvuče trenutne podatke o stresu i anksioznosti studenata, a ne da ih karakteriše, tako da se mogu ispitati trenutna ponašanja zajedno sa fizičkom aktivnošću, pušenjem cigareta i prosečnom ocenom tokom studiranja [30].

Ovo istraživanje se sprovodi u skladu sa stresom i anksioznosću među studentkinjama Univerziteta u Beogradu u Srbiji. Prema problemskoj izjavi u uvodu i uočenim nedostacima u pregledu literature, dva su pitanja definisana:

- 1- Da li je odvajanje roda radi boljeg razlikovanja stresa i anksioznosti u stanju da smanji grešku sa linearnim regresionim algoritmom?
- 2- U kojoj meri dodavanje ključnih karakteristika (pušenje, fizička aktivnost i prosečna ocena tokom studiranja) vezanih za stres i anksioznost među studentkinjama može smanjiti stopu grešaka linearog regresionog algoritma?

Na Slici 12. prikazan je istraživački okvir, a dodatni detalji objašnjeni su u različitim delovima poglavlja metodologije istraživanja.



*Slika 12. Blok dijagram, detekcija stresa i anksioznosti studentkinja*

## 4.2. Učesnici i instrumenti

Standardni upitnik distribuiran je putem *Google Forms*-a među 78 studenata Univerziteta u Beogradu. Nakon izvlačenja i rešavanja problema, distribuiran je među različitim grupama studenata na društvenim mrežama i putem mejla. Najviše učesnika bilo je sa Fakulteta organizacionih nauka, Medicinskog fakulteta i Stomatološkog fakulteta. Učestvovalo je 265 studenata.

U ovoj studiji je 231 odgovor bio korektan i korišćen za analizu. Većina učesnika (89,2%) bila je između 18 i 27 godina (Tabela 4).

Tabela 4. Demografski profil ispitanika

Karakteristike		Učestalost	Procent (%)
Pol	Ženski	173	74.9%
	Muški	56	24.2%
	Androgeni	2	0.9%
Starost	18 – 22	169	73.2%
	23 – 27	37	16%
	28 – 32	11	4.8%
	> 32	14	6%
Bračni status	Samci	214	92.6%
	Oženjen	15	6.6%
	Razveden	1	0.4%
	Udovac	1	0.4%
Nivo obrazovanja	Osnovne studije	196	84.8%
	Master	22	9.5%
	Magistar	3	1.3%
	Doktor nauka	10	4.4%

Pored toga, 92,6% učesnika su bili samci, i konačno, prikupljeni su atributi poput pola, starosti, bračnog statusa i obrazovnog nivoa.

Jedna od najčešćih metoda za merenje anksioznosti naziva se Inventar anksioznosti, tj. STAI upitnik [155]. Sastoji se od 20 stavki za stanje anksioznost i 20 stavki za procenu anksioznosti osobina. Rezultati su definisani u rasponu od 20 do 80, pri čemu viši rezultati ukazuju na veću anksioznost. Sve stavke su ocenjene na Likertovoj skali stanja anksioznosti (1-”uopšte ne”, 2-”donekle”, 3-”umereno” i 4-”veoma mnogo”) i slično za osobine anksioznosti (1-”skoro nikad”, 2-”ponekad”, 3-”često”, 4-”gotovo uvek”) [2], [4], [156]. Spilbergerov STAI rezultati su klasifikovani kao niski (20-40), umereni (41-50), i visoki (51-80) [150], [157].

U drugom delu ovog istraživanja iz STAI upitnika izabrana je sekcija o stanju anksioznosti sa 20 standardnih pitanja koja je podeljena među studentkinjama Univerziteta u Beogradu.

Takođe, prikupljeni su podaci sa 168 učesnika, a nakon detaljnijeg ispitivanja odabрано je 160 odgovora koji će se koristiti za analizu podataka. Učesnice su bile studentkinje uzrasta od 18 do 27 godina, a sve su bile neudate (Tabela 5).

*Tabela 5. Opis učesnika korišćen u istraživanju.*

Karakteristike		F	%
<b>Pol</b>	Ženski	160	100
<b>Starost</b>	18 – 22	136	85
	23 – 27	24	15
<b>Bračni status</b>	Samci	160	100
<b>Nivo obrazovanja</b>	Osnovne studije	152	95
	Master	7	4.3
	Doktor nauka	1	0.7

Definisani su rezultati stanja anksioznosti između 20 i 80. Brojevi između 20 i 40 označavaju najniži nivo anksioznosti kod učesnika, brojevi od 41 do 50 ukazuju na umerenu anksioznost, i od 51 do 80 ukazuju na najveći nivo anksioznosti [155]. Na kraju, stanje anksioznosti takođe koristi četvorostepenu Likertovu skalu od 1 "Uopšte ne" do 4 "Veoma mnogo"[4].

### 4.3. Analiza podataka

U prvom delu ove studije, a prema analizi podataka i ocenjivanju anksioznosti, pripremljen je konačni skup podataka ( $N=231$ ) i ocenjen pomoću metoda mašinskog učenja. Podaci su prikupljeni putem onlajn upitnika i uvezeni u CSV – Excel list sa podacima – kako bi bili analizirali. CSV je korišćen zato što u ovom slučaju za analizu korišćenja Pandas biblioteka. Stoga su izmerene karakteristike anksioznosti kako su izvučene u upitniku, a sistem je bio u stanju da predvidi razloge za anksioznost pojedinaca kao prediktor. Algoritmi mašinskog učenja kodirani su i implementirani pomoću programskog jezika Python (Jupiter Lab 3.2.1), 70% podataka je korišteno za obuku i 30% (0.3) za test. Karakteristike ovog istraživanja izvučene su iz sadržaja upitnika o anksioznosti kako bi se saznalo koji su faktori imali negativan uticaj na anksioznost studenata.

Zatim je u drugom delu ovog istraživanja za analizu pripremljen svaki uzorak sa 20 karakteristika. Pored ovih funkcija, tri odvojene funkcije su postepeno uključene u skup podataka. Biblioteke i paketi koji se koriste u ovom istraživanju nazivaju se NumPi, Pandas, Matplotlib, SciPi, Scikit-learn, k-means klasterizacija i drugi. Kodiranje je realizovano u Python-u. Procenat od 70% podataka odabran je za deo treninga modela, a 30% za test korak.

#### 4.4. Predobrada podataka

Nakon prikupljanja podataka, deo skala je obrnut, a zatim su sortirani rezultati između 20 i 80 [150]. Da bi se osigurala pouzdanost upitnika i dobijenih rezultata, ukupno je 231 uzorak prebačen u "IBM SPSS 26" softver. Budući da dobijeni *Cronbach*-ov Alfa treba da bude  $\geq 0,7$  ( $\alpha \geq 0,7$ ), utvrđena je pouzdanost upitnika, i nastavilo se sa pripremom podataka za dalju analizu [158].

Tabela 6. *Cronbach*-ova Alfa skupa podataka o anksioznosti.

Statistika pouzdanosti	
Broj stavki	Cronbachova Alfa
Stanje – Anksioznost (1 – 20)	0.89
Osobina – Anksioznost (21 – 40)	0.88
Ukupno (1 – 40)	0.93

Pored toga, Pirsonova korelacija između stanja i anksioznosti osobina bila je 0,83.

Generalno, predobrada podataka se vrši radi tačnosti i efikasnosti testiranja i obuke u mašinskom učenju kako bi se povećala pouzdanost [18]. U ovom skupu podataka, uzorci su postavljeni na redove, a atributi su postavljeni na kolone. Prethodna obrada podataka, uključujući čišćenje podataka, duplike, izbor primera, normalizaciju i ekstrakciju funkcija, imala je značajan uticaj na performanse u prvom delu ovog istraživanja.

Tokom filtriranja podataka, neke kolone su uklonjene iz procesa mašinskog učenja zbog nedostatka potrebe. Dupli podaci su takođe uklonjeni ili modifikovani kako bi se povećala tačnost izračunavanja. Štaviše, normalizacija podataka podrazumeva uklanjanje veoma velikih i veoma malih podataka koji su imali značajan uticaj na konačni rezultat (podela svakog nivoa sa normom je jednaka 1). Za standardizaciju podataka, svaki uzorak je oduzet od srednje vrednosti i podeljen standardnom devijacijom. Konačno, šum je dijagnostikovan sa izuzecima, i uklonjen iz skupa podataka.

Sledeće, na prvom stadijumu, jer je standard *STAI* upitnika određen od strane Spilbergera, broj određenih skala je obrnut pre bilo koje analize [150]. Onda su rezultati stanja anksioznosti izdvojeni i sortirani od 20 do 80 stepeni [8]. Pouzdanost skupa podataka je takođe dobijena ( $\alpha= 0.88$ ) softverom *IBM SPSS Statistics*.

U čišćenju podataka identifikovani su netačni zapisi iz skupa podataka i nepotpuni delovi stanja anksioznosti i zamjenjeni odgovarajućim opcijama. U fazi čišćenja podataka, kolone kao što su vreme i datum učešća učesnika su uklonjene, a radi lakšeg rada, komplikovane varijable su preimenovane sa komandom "*rename*".

Da bismo povezali karakteristike stanja anksioznosti sa tri ključne karakteristike, koristili smo komandu "contact" iz biblioteke *Pandas*. Pošto *Scikit-learn* nije bio u stanju da prihvati kategorijske karakteristike, *Pandas* "get\_dummies" naredba je korišćena za kodiranje značajnih numeričkih varijabli.

## 4.5. Algoritmi i funkcije mašinskog učenja

Ovo poglavlje pruža kratke informacije o jednom od algoritama mašinskog učenja koji je pokazao uspešne rezultate u ovom istraživanju. Nadalje, kao što je navedeno u pregledu literature u prethodnim studijama, algoritmi nadgledanog učenja bili su prikladni za ovu studiju.

Stanje anksioznosti i osobina anksioznosti su ispitani (trening i test) pomoću linearne regresije i *ridge* regresije, pri čemu su dobijeni rezultati bili isti, zbog čega je izabrana linearna regresija za korišćenje i objašnjenje. Takođe, linearna regresija je metoda koja se koristi za prediktivnu analizu u skupovima podataka [159]. Za rešavanje problema u regresiji, linearna regresija je jedan od uobičajenih algoritama u nadgledanom učenju koji može razviti optimizirana rešenja [160].

Linearni regresioni algoritam je imao za cilj da pronađe najprikladniju liniju kroz podatke, minimizirajući zbir kvadratnih razlika između posmatranih vrednosti i predviđenih linijom. Jednačina linije u jednostavnoj linearnej regresiji je:

$$y = \beta_0 + \beta_1 x$$

Gde je  $\beta_0$  i y-intercept a  $\beta_1$  je nagib linije.

Pseudo kod je objašnjen u nastavku:

```
[Algorithm LinearRegression
    Input: Feature vector X, target vector y
    Output: Coefficients β₀ and β₁

    Begin
        Calculate mean of X (mean_X) and y (mean_y)
        Calculate the slope β₁:
            β₁ = Σ ((Xᵢ - mean_X) * (yᵢ - mean_y)) / Σ
                ((Xᵢ - mean_X)²)
        Calculate the intercept β₀:
            β₀ = mean_y - β₁ * mean_X
    End]
```

Varijabla H je definisana kao ulazni faktor i kao ciljni vektor.

Varijabla  $\beta_1$  je poznata zajedno sa formulom za nagib, tako da je uključena kao kovarijansa i podeljena varijansom p.

Zatim se  $\beta_0$  koristi za određivanje presretanja koristeći srednje vrednosti od i, i izračunati nagib.

Koristili smo algoritam linearne regresije u *Python*-u i implementirali sledeći kod:

```
Import numpy as np

def linear_regression (X, y):

    # Calculate means
    mean_X= np.mean (X)
    mean_y= np.mean (y)

    # Calculate the slope β1
    numerator= np.sum ((X - mean_X) * (y - mean_y))
    denominator= np.sum ((X - mean_X) ** 2)
    betal= numerator / denominator

    # Calculate the intercept β0
    beta0 = mean_y - betal * mean_X
    return beta0, betal

# Example usage:
X = np.array([1, 2, 3, 4, 5])
y = np.array ([2, 4, 5, 4, 5])
beta0, betal= linear_regression (X, y)
print (f"Intercept (β₀): {beta0}, Slope (β₁): {betal}")
```

Prema vektoru ulaznog faktora  $X=[1, 2, 3, 4, 5]$ , i ciljni vektor  $y=[2, 4, 5, 4, 5]$ :

A. Calculate Means:

- $\text{mean\_}X=3$
- $\text{mean\_}y=4$

B. Compute Slope  $\beta_1$ :

- Numerator:  $\sum ((X_i - 3) * (y_i - 4)) = (1 - 3) * (2 - 4) + (2 - 3) * (4 - 4) + \dots = 2$
- Denominator:  $\sum ((X_i - 3)^2) = (1-3)^2 + (2-3)^2 + \dots = 10$
- $\beta_1=10/2=0.2$

C. Compute Intercept  $\beta_0$ :

Dakle, jednačina regresione linije je  $y = 3.4 + 0.2x$ .

Sve u svemu, pouzdanost obrasca u ovoj studiji zavisi od validnosti linearne regresije [161]. Ovaj algoritam je poznat kao fleksibilna i moćna tehnika predviđanja [162]. Podaci o obuci iz rezultata anksioznosti studenata definisani su na 70%, a 30% podataka odabrano je kao testni deo.

Implementacija linearne regresije kodirana je pomoću *Scikit-learn* biblioteke. Pored toga, i stanje anksioznosti i osobina anksioznosti su pripremljeni za prilagođavanje i predikciju.

Nakon procesa linearne regresije potrebno je izračunati razliku između predviđenih vrednosti i stvarnih vrednosti. *MSE* i *MAE* su takođe izračunate za ovaj skup podataka kako bi se procenili reziduali.

Ove funkcije su uspele da pronađu stopu rizika između stvarnih i procenjenih vrednosti. Ako greška modela dostigne nulu, model će biti optimalan.

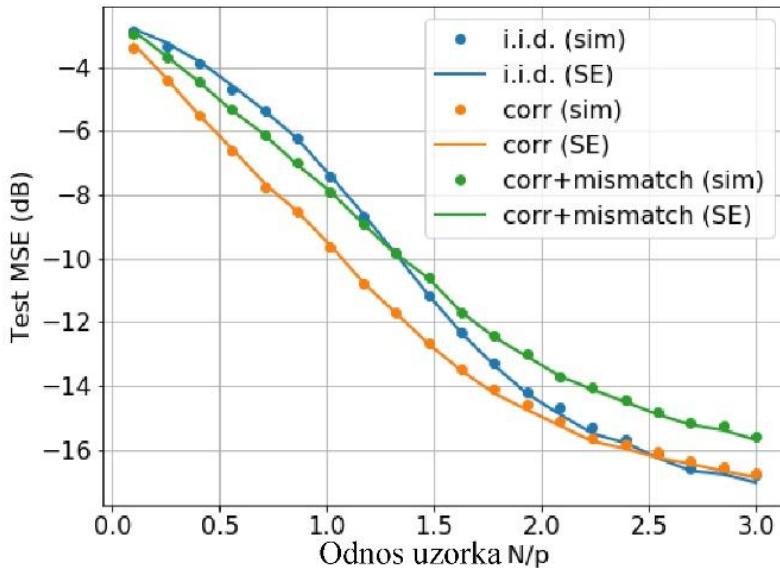
$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n} = \frac{\sum_{i=1}^n |e_i|}{n}$$

*MAE* je pokazatelj koji je na objektivan način uspeo izmeriti široku raznolikost disciplina mašinskog učenja. Grčki simbol ( $\Sigma$ ) se koristi za zbir, stvarne vrednosti za posmatranje se izračunavaju sa " $i_i$ ", a " $ks_i$ " izračunava vrednost za posmatranje, a ukupan broj posmatranja je prikazan sa " $n$ ". Aritmetički prosek apsolutnih grešaka  $|e_i| = |j_i - ks_i|$  gde je " $ks_i$ " izabrana kao prava vrednost, a " $\hat{Y}_i$ " je predviđanje [163].

$$MSE = \frac{1}{n} \sum_{i=0}^n (Y_i - \hat{Y}_i)^2$$

Dalje, " $n$ " označava broj tačaka podataka tako da " $Y_i$ " posmatra vrednosti " $\hat{Y}_i$ " *CanRcess* predviđa vrednosti [153].

Na primer, Slika 13 kao uzorak srednje kvadratne greške prikazuje procenu pomoću *SE* teorije [164].



Slika 13. Test srednja kvadratna greška pod nelinearnom procenom najmanjeg kvadrata [164].

Pored toga, za ovaj model je predložena funkcija *LASSO* kao efikasan pokazatelj. Faktori sa najvećim uticajem i na stanje anksioznosti i na anksioznost kao osobinu izvučeni su nakon treninga koristeći funkciju *LASSO* biblioteke *Scikit-learn* [154].

Ovde se koriste *ML* kodovi za proveru prekomerne i nedovoljne opremljenosti stanja anksioznosti primenom algoritma K-najbližih suseda.

```
# Provera prekvalifikacije i nedovoljne adaptacije od strane K-najbližeg suseda (KNN).
```

```
import numpy as np
import pandas as pd
import seaborn as sb
import sklearn.metrics
import matplotlib.pyplot as plt

from cmath import*
from sklearn import preprocessing
from sklearn.linear_model import LinearRegression
from sklearn.neighbors import KNeighborsClassifier
from sklearn.model_selection import train_test_split

data= pd.read_csv ( r'G:\PhD_Thesis\ML_dataset.csv' )

SAS_X= data.drop ( ['SAS', 'Q21', 'Q22', 'Q23', 'Q24', 'Q25', 'Q26', 'Q27', 'Q28', 'Q29', 'Q30', 'Q31', 'Q32', 'Q33', 'Q34', 'Q35', 'Q36', 'Q37', 'Q38', 'Q39', 'Q 0', 'TAS'], axis= 1)
```

```

SAS_Y= data ['SAS']

x_train, x_test, y_train, y_test= train_test_split (SAS_X, SAS_Y,
test_size= 0.3, random_state= 42)
reg= LinearRegression()
reg.fit (x_train, y_train)
y_predict= reg.predict (x_test)

neighbors= np.arange (1, 140, 1)
train_accuracy= np.empty ( len (neighbors) )
test_accuracy= np.empty ( len (neighbors) )

for i, k in enumerate (neighbors):
    knn_model= KNeighborsClassifier (n_neighbors= k)
    knn_model.fit ( x_train, y_train ) # imported data
    train_accuracy [i]= knn_model.score (x_train, y_train) #
Calculate of Train Accuracy
    test_accuracy[i]= knn_model.score (x_test, y_test)

plt.plot ( neighbors, train_accuracy, label= 'Train Accuracy' )
plt.plot ( neighbors, test_accuracy, label= 'Test Accuracy' )
plt.legend ()
plt.xlabel ( 'Numbers of Neighbours Randomly, State-Anxiety' )
plt.xticks ( [ 0, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120,
130, 140 ], [ '0', '10', '20', '30', '40', '50', '60', '70', '80',
'90', '100', '110', '120', '130', '140' ] )
plt.yticks ( [ 0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0
], [ '0.0', '0.1', '0.2', '0.3', '0.4', '0.5', '0.6', '0.7', '0.8',
'0.9', '1.0' ] )
plt.ylabel ( 'Accuracy' )
plt.grid ()
plt.show ()

```

Gornji kod je pokazao uzorke koji su nasumično izvučeni iz skupa podataka o anksioznosti. Ovaj kod takođe argumentuje u pogledu tačnosti modela.

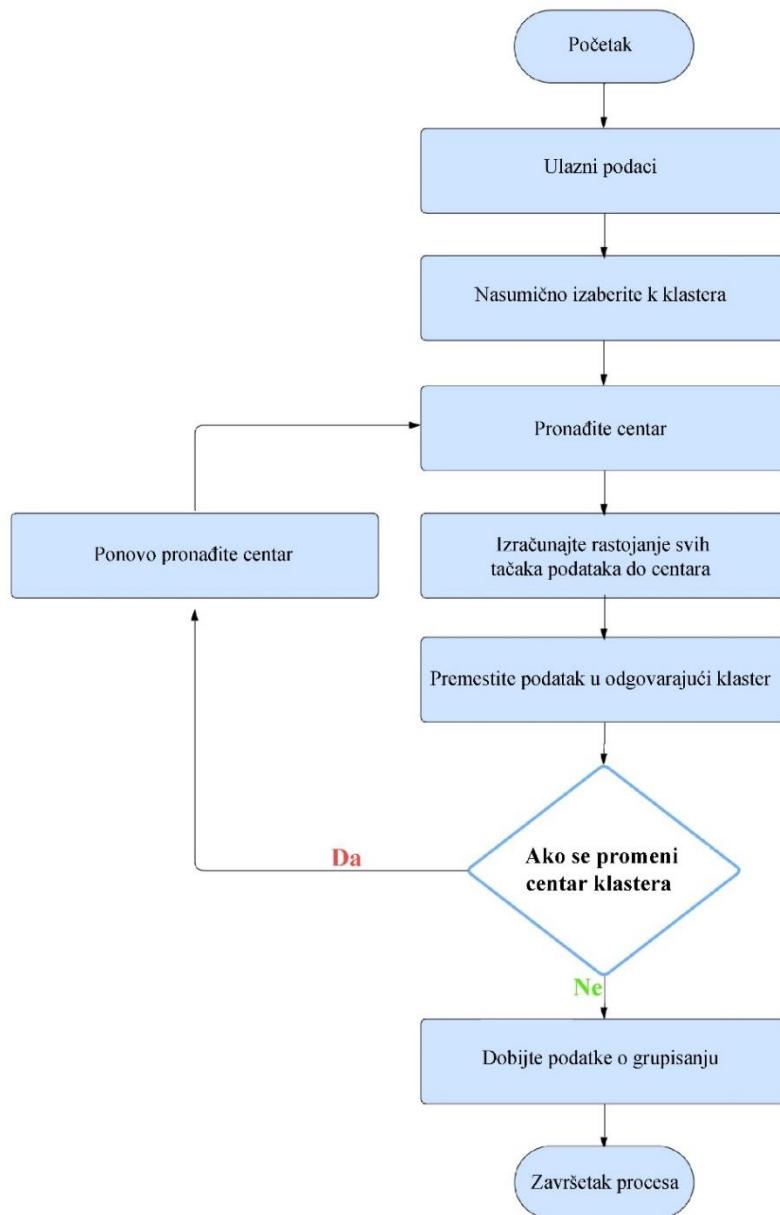
U osnovi, kao što se tvrdi u pregledu literature, otkrivanje stresa ili anksioznosti treba analizirati pomoću algoritama nenadgledanog učenja. Pored toga, prethodne studije su izvestile da je otkrivanje anksioznosti korišćenjem nadgledanih algoritama mašinskog učenja kao što je algoritam linearne regresije bilo u stanju da otkrije anksioznost sa većom tačnošću [77]. Pored toga, ona istraživanja koja su detektovala anksioznost korišćenjem klasifikacije nisu imala visoko kredibilne performanse i tačnost [121], [148], [165].

Dakle, vizualizacija višestruke regresione analize anksioznosti slučajnog stanja koristeći ključne karakteristike korišćena je u drugom delu ove studije [166]. Pored višestruke regresione analize, tehnika toplotne mape se koristi za potvrđivanje korelacije osobina stanja

anksioznosti. Korelaciona matrica pokazuje linearni odnos između dve promenljive, a vrednosti su definisane između -1 i +1 [167].

Konačno, za provođenje sličnih grupnih opažanja u skupu podataka, odabrana je klasterska analiza – *k-means* algoritam [168]. Greške ovog istraživačkog modela koji je definisan linearnim regresionim algoritmom su izdvojene sa funkcijama rizika kao što su  $R^2$ , *MAE*, *MSE* i *RMSE* i za fazu pre i posle intervencije [77], [169].

Konačno, algoritam grupisanja zasnovan na *k-means* vrednostima omogućio je kategorizaciju skupova varijabli (Slika 14).



Slika 14. *K-means* komponente algoritma za grupisanje.

Metrika Euklidovog kvadratnog rastojanja izabrana je kao mera udaljenosti [170]. Analize klastera su izvedene da izdvoje različite klastere stanja anksioznosti zasnovane na 20 pitanja iz standardnih upitnika sa tri ključna faktora pušenje cigareta, fizička aktivnost i prosečna ocena tokom studiranja.

## 5. Analiza rezultata

U prvom stepenu, pre vizualizacije ili prethodne obrade, pouzdanost svakog dela pitanja iz upitnika anksioznosti određena je Kronbahovim alfa koeficijentom, i vrednost anksioznosti stanja sa 0,89, a vrednost anksioznosti osobina postignuta je sa 0,88 (Tabela 6). Zatim su izračunati rezultati za svaki deo anksioznosti (Tabela 7). U stanju anksioznosti 89 studenata je bilo na najnižem nivou kategorije anksioznosti, 90 studenata je bilo umereno, a 52 studenata je imalo visoku anksioznost. U anksioznosti osobina, 81 student je uključivao nizak nivo anksioznosti, 100 je bilo umereno, a 50 studenata je imalo visok nivo anksioznosti.

Tabela 7. Rezultati dobijeni analizom STAI upitnika.

Testiranje	Ocena anksioznosti			
	Nizak	Umereno	Visoko	Ukupni prosek
Anksioznost stanja	89	90	52	43,75 (Od 20 Do 80)
Anksioznost osobina	81	100	50	43,74 (Od 20 Do 80)

Prosečna anksioznost studenata je prijavljena kao umerena, tako da je prosečno stanje anksioznosti pokazalo 43,75 od 80 poena, a prosečna osobina anksioznosti 43,74 od 80. Pored toga, prikupljeni su neki od detalja koji mogu imati negativne efekte na anksioznost studenata (Tabela 8). Među studentima, 130 pojedinaca (56,3%) bilo je na prvoj godini studija na univerzitetu, 38 (16,5%) studenata druge godine, 23 (10%) studenata treće godine, 28 (12,1%) studenata četvrte godine, a 12 (5,1%) njih bili su studenti poslediplomske studije. Prosečna ocena tokom studiranja je takođe jedan od glavnih faktora koji može imati velikog uticaja na anksioznost studenata. Pored ovih rezultata, 76 studenata (32,9%) imalo je prosečnu ocenu tokom studiranja od 6,00 do 7,99 od 10,00, a 155 njih (67,1%) imalo je prosečnu ocenu tokom studiranja između 8,00 i 10,00.

Ustanovljeno je da je 124 polaznika (53,7%) prvi put uspešno položilo svoje predmete, kod 71 od njih (30,7%) se nekada dešavalo da iz prvog puta ne polože ispit, te na kraju, 36 studenata (15,6%) je više puta polagalo ispite. Pitani su i o statusu njihovog zaposlenja, 171 (74%) student je bio zaposlen, a 60 njih (26%) nije bilo zaposleno. Zatim, 91 student (39,4%) je primalac stipendije ili studentskog kredita, a 140 studenata (60,6%) nikada nije koristilo nikakve stipendije ili studentske kredite. Od njih je traženo da odgovore ko je podržavao njihove školarine ili stipendije tokom studija. Školarinu samostalno plaća 37 studenata (16%), 114 (49,4) su podržali roditelji, a na kraju je 76 studenata (32,9%) iskoristilo državno finansiranje ili stipendije za svoje studije.

Tabela 8. Više informacija o studentima.

Pitanja	Opcije	Učestalost	Procenat
1. Godina studija	Prva	130	56.3
	Druga	38	16.5
	Treća	23	10
	Četvrta	28	12.1
	Poslediplomske studije	12	5.1
2. Prosek ocena	6 – 6.99	7	3
	7 – 7.99	69	29.9
	8 – 8.99	99	42.9
	9 – 10.00	56	24.2
3. Da li se ikada dogodilo da je jednom ili više puta ispit polagan da bi bio položen?	Da – jednom	71	30.7
	Da – mnogo puta	36	15.6
	Nikad	124	53.7
4. Jeste li zaposleni?	Da	171	74
	Ne	60	26
5. Da li ste korisnik stipendije ili studentskog kredita?	Da	91	39.4
	Ne	140	60.6
6. Ko podržava vaše stipendije ili školarine za studiranje?	Država	76	32.9
	Kompanija	4	1.7
	Vaši roditelji	114	49.4
	Sami	37	16

U nastavku analize, razmotreno je mišljenje učesnika o njihovoj upotrebi programa pametne zdravstvene zaštite, kao i o njihovom interesovanju za metode i aplikacije za predviđanje anksioznosti tehnologijom mašinskog učenja (Tabela 9). Prvo pitanje (K1) bilo je o upotrebi mobilnih zdravstvenih aplikacija poput upravljanja anksioznošću putem pametnog telefona, a drugo pitanje (K2) bilo je o njihovom interesu za predviđanje anksioznosti studenata tehnologijom mašinskog učenja (Tabela 9).

Tabela 9. Pogodna pitanja u vezi sa interesovanjem za korišćenje pametne zdravstvene zaštite među univerzitetskim studentima.

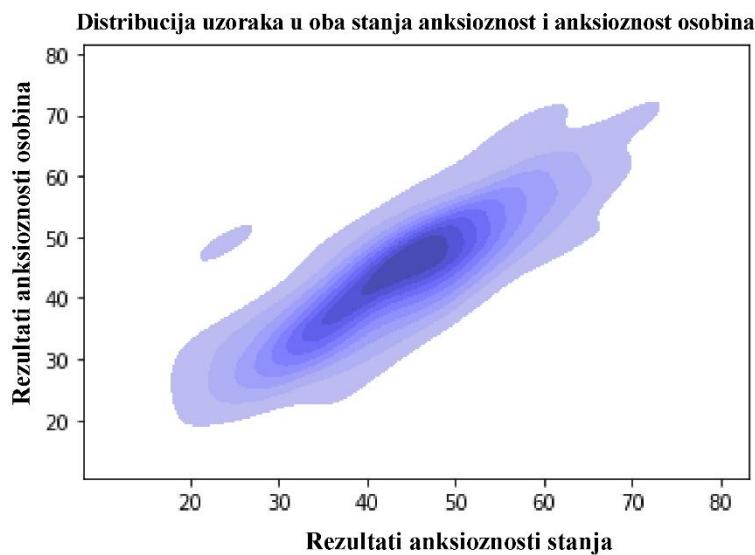
Pitanja	Opcije	Učestalost	Procenat
K1	A. Često koristim ove tehnologije.	27	11.7
	B. Skoro 4 puta mesečno.	15	6.5
	C. Povremeno koristim ovu tehnologiju.	37	16
	D. Ja ne koristim ove tehnologije.	152	65.8
K2	A. Da, voleo/volela bih.	75	32.5
	B. Mogao/mogla bih ga koristiti kasnije.	102	44.2
	C. Ne, ne bih ga rado koristio/koristila.	54	23.3

U nastavku rezultata postavljeno je pitanje o fizičkim aktivnostima studenata, kao o njihovim navikama u vezi sa pušenjem cigareta (Tabela 10). Rezultati su pokazali da 179 učesnika (77,5%) nisu pušači, a 52 (22,5) njih je naviklo da puši cigarete. Pored ovih sadržaja, 140 studenata (60,6) je u svom životu imalo adekvatnu količinu fizičkih aktivnosti (oko 150 minuta sedmično), ali 91 studenata (39,4%) nema dovoljno fizičkih aktivnosti tokom sedmice.

Tabela 10. Pušenje i fizičke aktivnosti kod učenika.

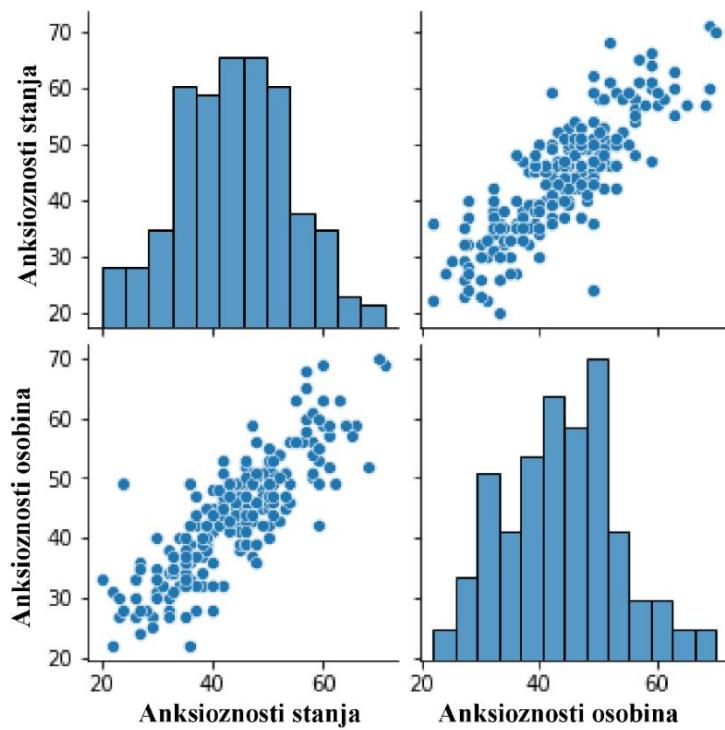
Ne.	Pitanja	Opcije	Učestalost	%
1	Pušenje cigareta	Ne	179	77.5
		Da	52	22.5
2	Fizičke aktivnosti (približno 150 minuta nedeljno).	Da	140	60.6
		Ne	91	39.4

Iako su korisne informacije vezane za stres i anksioznost, kao što su pušenje cigareta, fizička aktivnost i prosečna ocena tokom studiranja prikupljene u ovoj studiji, one u drugim studijama nisu korišćene za bilo koju klasifikaciju ili analizu primenom algoritmima mašinskog učenja. Slika 15 prikazuje raspodelu stanja anksioznosti i osobine anksioznosti, koja je izvučena iz *Seaborn Kernel Distribution Estimation* grafika dobijenog korišćenjem programskog jezika *Python*. Nivo anksioznosti studenata, naveden od 20 do 80, i srednja raspodela oba režima tačno su prikazani. Grafik predstavlja distribuciju *STAI* upitnika koristeći kontinuiranu krivu gustine verovatnoće.



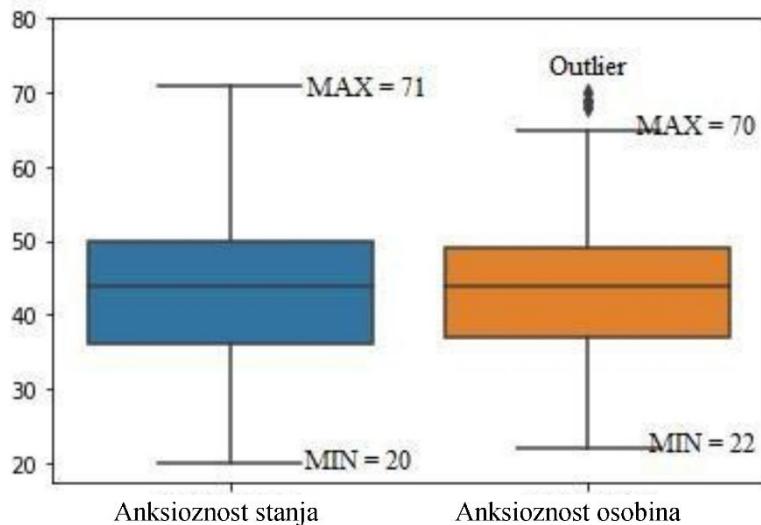
*Slika 15. Distribucija uzorka za anksioznost stanja i anksioznost osobina.*

Slika 16 prikazuje parni dijagram skupa podataka (kombinacija dva skupa podataka kao matrice), a ovaj grafikon stvara funkciju tako da je svaka promenljiva ovog skupa podataka podeljena između x-ose i y-ose. Veoma malo izuzetaka je takođe jasno prikazano na ovoj slici, tako da je očigledno da nije bilo velikog značaja u rezultatima i tačnosti modela.



*Slika 16. Odnos anksioznosti satanja i anksioznosti osobina u skupu podataka.*

Zatim, na Slici 17, prikazuje se rezime skupa podataka od 231 ispitanika, u prvom kvartilu stanja anksioznosti, minimalni odgovor je pokazao 20 od 80, a 71 od 80 je bio maksimalni opseg u trećem kvartalu. Za osobinu anksioznosti koja je prikazana narandžastom bojom na Slici 17, minimalni broj bio je 22 od 80, a 70 od 80 bio je treći kvartal i maksimum.



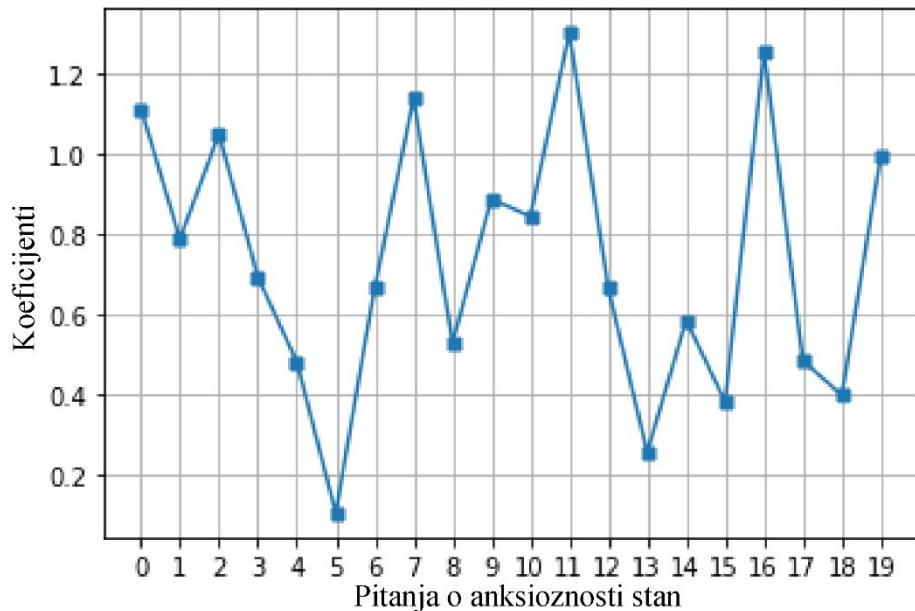
Slika 17. Raspodela razlika u izmerenim rosečnim vrednostima između stanja anksioznosti i osobine anksioznosti u celokupnom skupu podataka.

Iako su šumovi uklonjeni iz skupa podataka, ekstremne vrednosti su izračunate. Na Slici 17 prikazan je spoljni prikaz skupa podataka o anksioznosti osobina, a ovaj faktor je uzrokovao malo uticaja na izlaz. Na kraju, nakon posmatranja 70 uzoraka podataka, i kao što je gore pomenuto, izvršena je operacija standardizacije, a zatim su podaci definisani u programu mašinskog učenja za testiranje i obuku. Rezultati mašinskog učenja sa 70 uzoraka nisu imali prihvatljivu tačnost. Stoga, nakon što je željeni broj uzoraka dostigao 231 studenata, ponovo su obavljeni testovi i dobijena je veoma visoka tačnost iz linearne regresione algoritma (Tabela 11). Takođe treba napomenuti da su, kao što je gore rečeno, sve mere ispitane odvojeno i za anksioznost stanja i za anksioznost osobina.

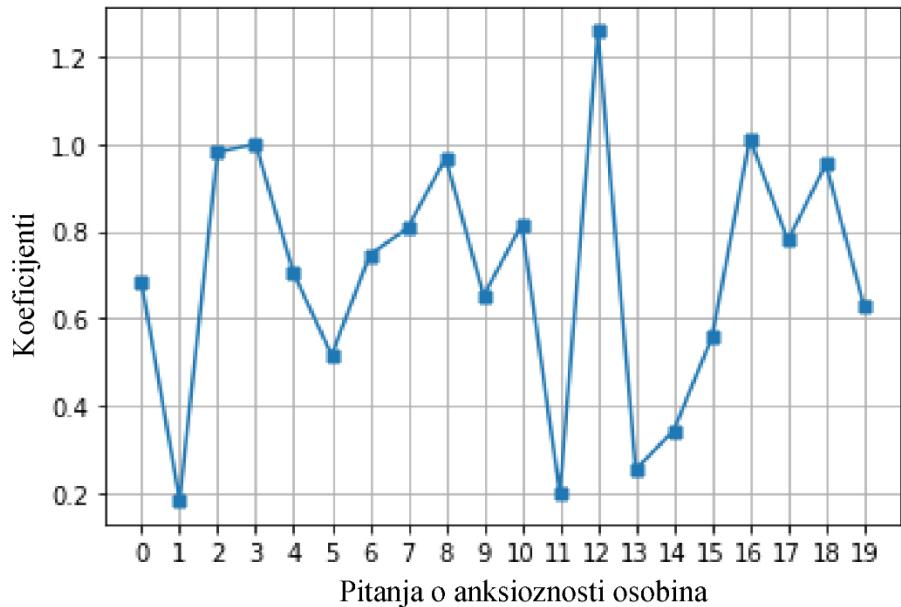
Tabela 11. Metrika greške / tačnosti anksioznosti stanja i anksioznosti osobina u linearnoj regresiji pomoću MAE i MSE.

Vrsta algoritma	Vrsta anksioznosti	MAE	MSE
Linearna regresija	Anksioznost stanja	7.86	7.80
Linearna regresija	Anksioznost osobina	5.68	9.66

Srednja kvadratna greška je procenjivala vrednost greške u statističkim modelima, a vrednost  $MSE$  je prikazivala sistemsku grešku blizu nule (Tabela 11). Na Slici 18 i Slici 19 prikazana je *Lasso* regresiona funkcija koja je pronašla faktore sa najvećim uticajem u anksioznosti stanja i anksioznosti osobina nakon treninga skupa podataka primenom linearne regresije.



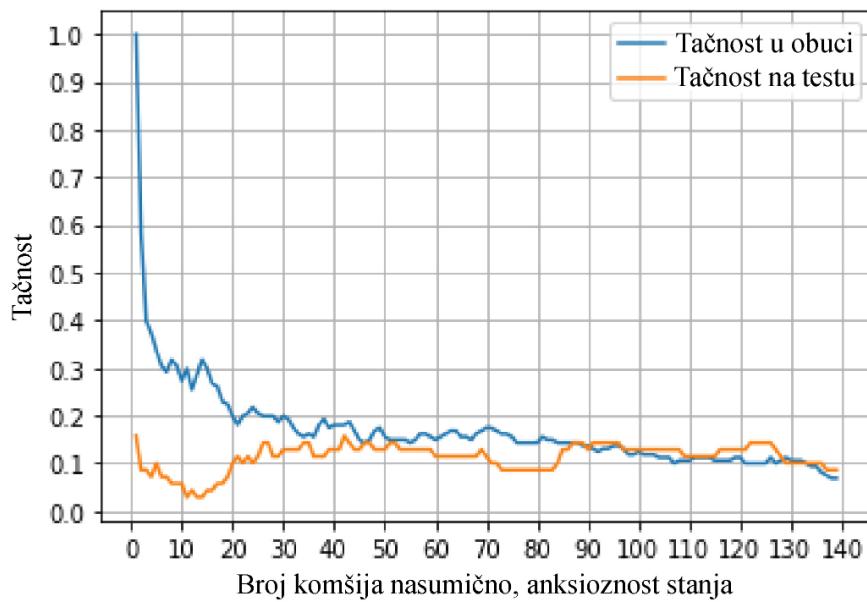
Slika 18. Opcija sa najvećim uticajem nakon treninga skupa podataka anksioznosti stanja.



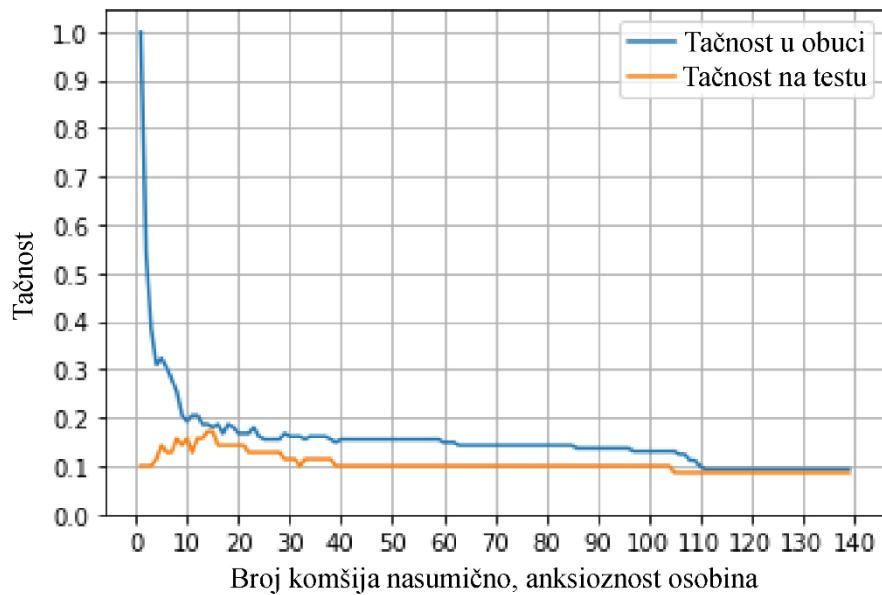
Slika 19. Opcija sa najvećim uticajem nakon treninga podataka o anksioznosti osobina.

Slika 18 je pokazala da je 12. pitanje u anksioznosti stanja imalo najveći uticaj nakon treninga, a Slika 19 je pokazala da je 13. pitanje bilo najvažniji faktor u anksioznosti osobina nakon trening sekcije. Na kraju, algoritam K-najbližih suseda korišćen je u ovom smislu da pronađe i prikaže način treniranja, kao i probleme preprilagođenosti (*overfitting*) i nedovoljne prilagođenosti (*underfitting*).

Slika 20 je pokazala da je oko 140 uzoraka koji su nasumično izvučeni iz skupa podataka o stanju anksioznosti kodirano, a do 20. blizine uzorka uočeni su problemi s prekomernim prilagođavanjem. Slika 21 iz skupa podataka o anksioznosti osobina takođe je pokazala tačnost modela počevši od uzorka 85 nadalje, a problemi prekомерне i nedovoljne prilagođenosti nisu viđeni u osobinama anksioznosti.



Slika 20. Provera preprilagođenosti i nedovoljne prilagođenosti stanja anksioznosti primenom algoritma K-najbližih suseda.



*Slika 21. Provera preprilagođenosti i nedovoljne prilagođenosti anksioznosti osobine primenom algoritma K-najbližih suseda.*

Dalje, u drugom delu ovog istraživanja kada su razmatrane samo studentkinje, rezultati analize stanja anksioznosti pokazali su da je 59 njih bilo u niskoj kategoriji anksioznosti, 59 od njih je bilo umereno, a samo 42 studentkinje imale su visok nivo stresa ili anksioznosti. Posmatranja su takođe pokazala da su ukupni prosečni rezultati anksioznosti u ovom istraživanju bili 44,39 od 80, pri čemu je većina učesnika (95% studentkinja) bila na osnovnim studijama, prema Tabeli 5 i Tabeli 12.

*Tabela 12. Rezultati i rezultati anksioznosti stanja.*

Ocena anksioznosti				
Vrsta testa	Nizak	Umereno	Visoko	Ukupni prosek rezultata od 20 do 80
Stanje-anksioznost	59	59	42	44.39

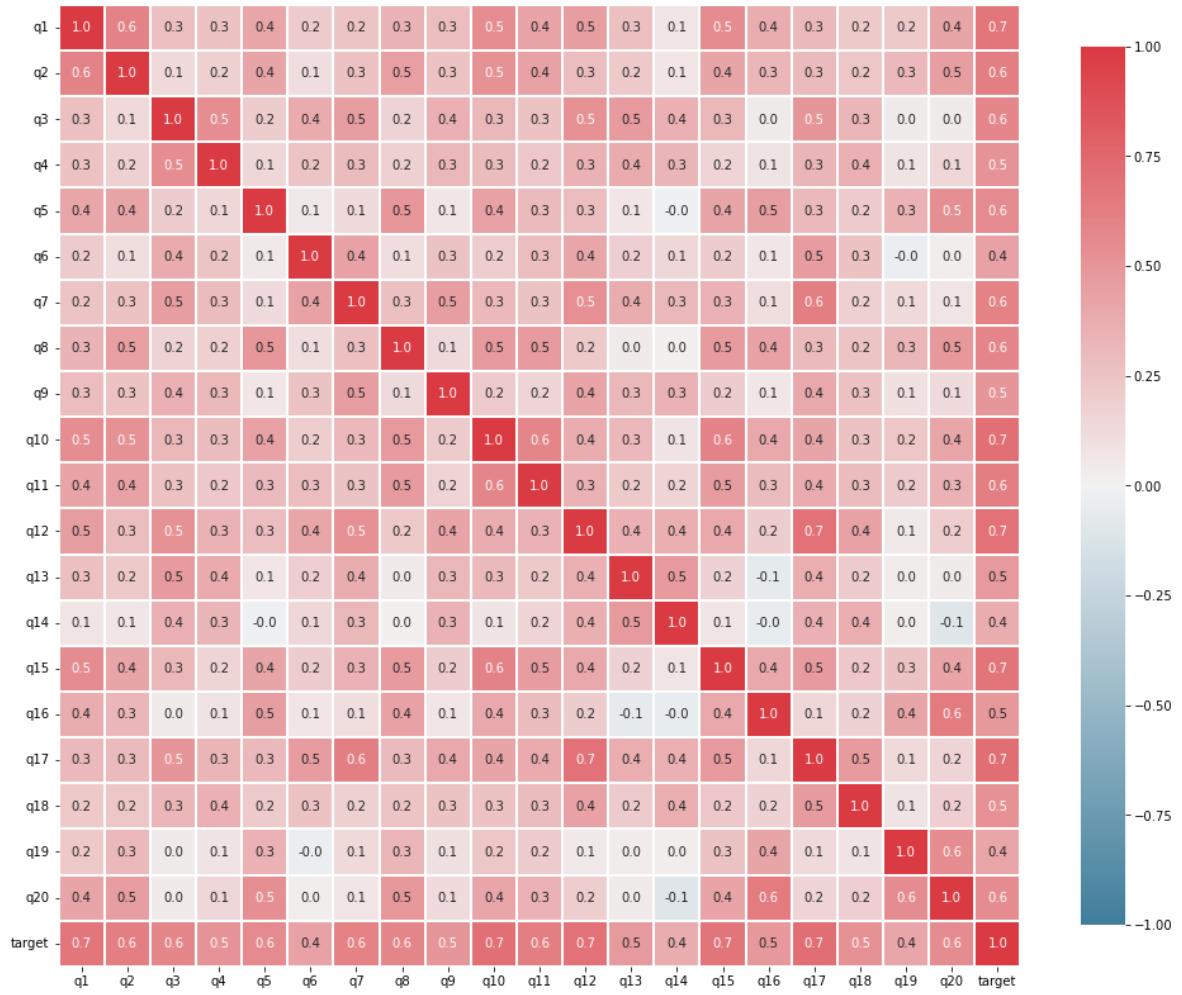
Rezultati ove istraživačke studije pokazali su da 120 studentkinja nisu pušači, ali 40 njih jeste. Stopa fizičke aktivnosti nije bila povoljna, pa su 94 studentkinje otprilike imale minimum od 150 minuta fizičke aktivnosti sedmično, a 66 vežba manje od 150 minuta sedmično (Tabela 13).

Tabela 13. Pušenje cigareta, fizičke aktivnosti i izveštaji o prosečnoj oceni tokom studiranja kod studentkinja.

Ne.	Ključni faktori/osobine	Odgovori	
		Ne	Da
1	Pušenje cigareta	120	40
2	Fizičke aktivnosti (oko 150 min/sedmica)	66	94
3	Prosečna ocena tokom studiranja	6-6.99= 5 7-7.99= 48 8-8.99= 68 9-10.00= 39	

Pored ovih karakteristika, najnoviji faktor koji ima značajan uticaj na stres ili anksioznost studentkinja u ovoj studiji je navedena prosečna ocena tokom studiranja. Rezultati su pokazali da je samo 5 studentkinja imalo nizak prosek ocena između 6 i 6,99, dok je prosek ocena studentkinja bio između 7 i 7,99 kod 48 učesnica u istraživanju. Zatim, 107 studentkinja je imalo najbolju prosečnu ocenu tokom studiranja između 8 i 10, prema Tabeli 13. Pre analize stanja anksioznosti podataka pomoću linearne regresije i klaster analize, izračunata je kovarijantna matrica. Prema Changu [167], linearna povezanost između dve varijable definiše se u opsegu od -1 do +1, pri čemu što su vrednosti bliže +1, to je veća korelacija između dve varijable. Slika 22 takođe prikazuje matricu korelacija u toplotnoj mapi generisanoj iz skupa podataka o stanju anksioznosti.

Tako je za analizu podataka odabранo 70% skupa podataka za obuku, a 30% za fazu testiranja. Ova kategorizacija nam je dala najbolje rezultate u smanjenim greškama. Dakle, koeficijent determinacije ili  $R^2$  kao statistička mera u modelu linearne regresije definiše proporciju varijanse u zavisnim varijablama.  $R^2$  i za fazu pre i za fazu posle intervencije pokazuje najbolji rezultat (Tabela 14).



Slika 22. Korelaciona matrična toploplotna mapa generisana iz skupa podataka o stanju anksioznosti.

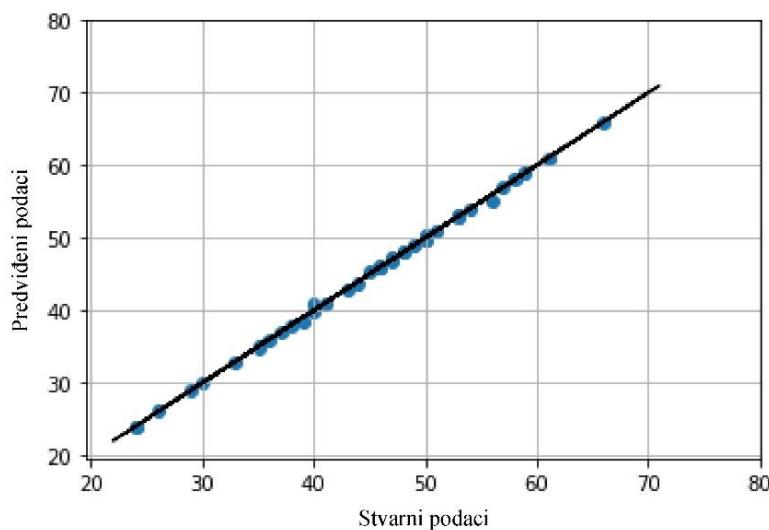
Tabela 14. Rizične funkcije između faze pre i faze nakon intervencije.

Funkcije rizika	Faza prije intervencije	Postintervencijska faza
R^2	1.0	1.0
MAE	9.47	8.14
MSE	1.40	1.31
RMSE	1.18	1.14

Greška mašinskog učenja (ovi rezultati sa "test\_size = 0.3" i "random\_state = 42" pokazuju najbolje vrednosti, a ne druge promenljive.

Što su *MAE*, *MSE* i *RMSE* bliži nuli, to je model tačniji i bliži optimalnom tako da ove funkcije rizika pokazuju prihvatljiv izlaz. Ovo istraživanje takođe pokazuje da ako imamo ključne faktore povezane sa ženskim stresom i anksioznosću može da pomogne model višestruke linearne regresije da smanji stopu grešaka. Drugi stepen izdvajanja grešaka iz ovog modela zvani faza posle intervencije pokazuje manje grešaka u poređenju sa predinterventnim stadijumom (Tabela 14).

Nakon izvlačenja grešaka pre i posle intervencione faze sa najboljom performanse, kodirana je vizualizacija podataka. Da bi obezbedili podatke vizualizacije gledamo u rezultate stanja anksioznosti koristeći tri ključna faktora. U ovom modelu i po Slici 23, ispitujemo da li predviđanje rezultata anksioznosti odgovara greškama koje su pomenute ili ne.



Slika 23. Predviđanje linearног regresionог modelа za stanje anksioznosti postintervencijske faze.

Kao što je gore objašnjeno, svaki uzorak skupa podataka (*N*) sa karakteristikama je procenjen na modelu višestruke linearne regresije. Kako su rezultati pokazali najbolje rezultate u fazi nakon intervencije, ovaj model je programiran sa tri ključne karakteristike. Štaviše, analiza primenom klaster algoritma je programirana da razlikuje različite klastere stresa i anksioznosti kod studentkinja na osnovu njihovih karakteristika.

Klasteri su okarakterisani kao najbolja rešenja za klasterizaciju. Nakon skupa podataka o anksioznosti stanja usledila je analiza tri ključne karakteristike, pušenje, fizička aktivnost i prosečna ocena tokom studiranja. Zaista, većina studentkinja zadržala je iste klastere koji su izvučeni glavnim modelom.

Tabela 15 prikazuje karakteristike studentkinja u anksioznosti stanja i sa postintervencijskom fazom.

Tabela 15. Karakteristike klastera anksioznosti stanja u postintervencijskoj fazi.

Karakteristike	Klaster 1 N=94	Klaster 2 N=66
Pušenje cigareta (da)	72.34%	49.21%
Fizičke aktivnosti (da)	9.75%	75.75%
Prosečna ocena tokom studiranja	6-6.99= 3.19% 7-7.99= 27.65% 8-8.99= 42.55% 9-10.00= 26.59% Niska= 24.46%	6-6.99= 4.54% 7-7.99= 30.3% 8-8.99= 42.42% 9-10.00= 22.72% Niska= 34.84%
Totalna anksioznost stanja	Umereno= 37.23% Visoka= 38.29%	Umereno= 31.81% Visoka= 33.33%

Da bi se objasnila analiza klastera koja je dobijena algoritmom *k-means*, izdvojena su dva klastera sa odgovarajućim rezultatima:

- ✚ Prvi je klaster 1 (N=94), koji sadrži najviše učesnika u skupu podataka. Ovaj algoritam je pokazao da su studentkinje patile od anksioznosti zbog visoke stope pušenja (72,34%) i niskog nivoa fizičke aktivnosti (9,75%). Studentkinje sa prosečnom ocenom tokom studiranja su okarakterisane srednjim procentom anksioznosti. Kao rezultat, u ovom klasteru, visok nivo stresa ili anksioznosti među studentkinjama (38,29%) prikazao je maksimalnu stopu u poređenju sa niskim nivoom (24,46%) i umerenim nivoom (37,23%) anksioznosti, prema Tabeli 15.
- ✚ Drugo, *k-means* algoritam je kategorisao klaster 2 sa 66 studentkinje (N=66). U ovom klasteru stopa pušenja cigareta među studentkinjama kategorisana kao niska (49,21%) u poređenju sa klasterom 1, a fizičke aktivnosti (75,75%) takođe su pokazale najvišu stopu u poređenju sa klasterom 1. Štaviše, samo je stopa prosečne ocene tokom studiranja u klasteru 2 bila nešto slabija od klastera 1. Međutim, učesnici u klasteru 2 iskusili su manje anksioznosti u odnosu na klaster 1, tako da je visok nivo anksioznosti bio 33,33%, a nizak nivo 34,84%, a postojao je prihvatljiv rezultat u Klasteru 2 zbog takve kategorije, prema Tabeli 15.

## 6. Diskusija

Danas je *COVID-19* poznat kao jedan od glavnih razloga za anksioznost [171]. Kao što je gore spomenuto, period obrazovanja je osjetljivo vreme i studenti su oni koji su ranjivi, pa se ova studija fokusirala na predviđanje stresa i anksioznosti studenata korišćenjem algoritama mašinskog učenja i funkcija za razvoj pametnih zdravstvenih usluga. Najmlađim studentima može biti teško da prepozna anksioznost, stoga korišćenje algoritama mašinskog učenja za otkrivanje i predviđanje anksioznosti može biti razumno rešenje [77]. Međutim, usluge pametne zdravstvene zaštite značajne su još su u ranom detinjstvu [48], a većina studenata u ovom istraživanju (65,8%) nikada nije koristila takve tehnologije (Tabela 9).

Pored toga, samo 23,3% studenata izjavilo je da ne bi želeli da koriste tehnologiju mašinskog učenja za predviđanje svoje anksioznosti (Tabela 9). Razmotreni su detalji u svakodnevnom životu koji mogu izazvati anksioznost među mladim studentima. Na primer, iako je korišćenje javnih bicikala korisno, problem sa parkiranjem može izazvati anksioznost [172].

Ovo istraživanje ispitalo je neke slučajeve koji mogu uticati na anksioznost studenata, kao što su godina studija, prosečna ocena, polaganje ispita više od jednom, status zaposlenja i situacija sa stipendijama ili studentskim kreditima za školarinu za studiranje. Kao što je ranije rečeno, većina nastave na univerzitetu za ispitnike koji su učestvovali u istraživanju održana je u onlajn kontekstu, a kao što pokazuje tabela 10, zbog *COVID-19*, 39,4% studenata nije radilo dovoljno fizičkih aktivnosti nedeljno [98], [109]. Štaviše, prethodno istraživanje je tvrdilo da su studenti koji su imali anksioznost verovatnije pušači [42].

Tabela 10 takođe pokazuje da je 52 studenta naviklo na pušenje, što je jedan od vitalnih razloga za umerenu anksioznost studenata. Dakle, prema dobijenom materijalu i diskutovanom, stopa anksioznosti (Tabela 7) čini se razumnim odgovorom. Anksioznost stanja ukazuje na fiziološke privremene reakcije direktno povezane sa štetnim uslovima u određenom trenutku, s druge strane, anksioznost osobina tvrdi osobinu ličnosti i opšte stanje anksioznosti [173]. U ovoj studiji, anksioznost stanja i osobina ispitivani su odvojeno [4].

Eksperimenti su pokazali neprihvatljive rezultate nakon ispitivanja 70 uzoraka, a kada je set podataka dostigao 231 povoljan slučaj, metrika greške ili tačnosti anksioznosti stanja i anksioznosti osobina postigla je prihvatljive rezultate, što pokazuje zadovoljavajuće rezultate u odnosu na sprovedene studije u tom pogledu [21], [77], [174].

Jedna od studija radila je na stanju i osobinama anksioznosti korisnika primenom *STAI* upitnika, te društvenom angažmanu broja korisnika na X-u koristeći linearnu regresiju. Pored toga, naši *MSE* izlazi (Tabela 11) su pokazali nekoliko prihvatljivijih rezultata u odnosu na prethodna istraživanja [77].

Pored toga, u drugom istraživanju koje se fokusiralo na klinički uzorak za predviđanje anksioznosti 101 učesnika na osnovu *STAI* upitnika, korišćen je algoritam klasifikacije stabla odlučivanja sa 80,50% tačnosti [21]. Takođe, još jedno istraživanje koje je prikupilo podatke o anksioznosti 125 učesnika iz *STAI* upitnika i analiziralo ih koristeći *random forest* algoritam

dostiglo je tačnost predviđanja od 74,18% [174]. Na Slici 18 možemo videti da korisnici sa ovim stanjima (Tabela 7 i Tabela 10) mogu da se suoče sa nervozom u svom životu.

Na Slici 18 prikazana je opcija s najvećim učinkom nakon treninga modela o anksioznosti stanja. Pored toga, Slika 19 pomoću funkcije *LASSO* prikazuje opciju sa najvećim uticajem nakon treninga modela o anksioznosti osobine. Ovi rezultati pokazuju da zbog pandemije *COVID-19* i nekoliko problema u obrazovnom periodu, neki od studenata imaju anksioznost, ali generalno se osećaju sigurno.

Nadalje, trenutna studija uvodi obrazac detekcije i predviđanja stresa i anksioznosti studenata korišćenjem tehnologije mašinskog učenja, tako da ovaj obrazac može poboljšati usluge pametne zdravstvene zaštite. Performanse linearног regresionог algoritma se procenuju korišćenjem *KNN* algoritma u proveri prekomernog i nedovoljnog prilagođavanja za anksiozna stanja i anksioznost osobina. Na Slici 20, otprilike između 90. i 125. faktora, jasno je da je tačnost treninga modela u našem sistemu povećana i stabilna. Iako Slika 21 nije dotakla tačku učenja, ova slika prikazuje opseg napretka i nalazi se blizu tačke učenja, posebno približno od 110. faktora nadalje. Pored ovih karakteristika, Slika 21 pokazuje praćenje tačnosti treninga bez preteranog prilagođavanja i nedovoljnog prilagođavanja anksioznosti osobina od strane *KNN*-a, tako da je do 20. faktora u anksioznosti stanja viđeno malo problema sa preprilagođavanjem modela.

Sve u svemu, implementacija ovog istraživanja omogućava istraživačima da saznaju o ozbiljnim problemima koji utiču na anksioznost, a takođe znaju kako se mašinsko učenje može koristiti za predviđanje i analizu anksioznost učesnika sa najmanjom greškom.

Sledeće, većina učesnika (73,74%) među studentkinjama u drugom delu ovog istraživanja imala je nizak i umeren nivo anksioznosti, dok 75% njih nije naviklo da puši cigarete, i 58,75% su navikle na fizičku aktivnost sa prosečno 150 minuta sedmično. Njihova prosečna ocena tokom studiranja je takođe prijavljena srednja, pa njihov umeren nivo anksioznosti deluje razuman.

Prema uvodnom delu i rezultatima ovog istraživanja, odricanje od ovih ključnih karakteristika moglo bi imati negativan uticaj na stres ili anksioznost studentkinja [11], [42], [43], [45], [46]. Ova činjenica se jasno vidi u rezultatima ovog istraživanja.

Slika 22 prikazuje linearnu asocijaciju između dve promenljive, a korelacioni matrični grafikon definiše linearnu asocijaciju. U delu upitnika o anksioznosti stanja bilo je 20 standardnih pitanja, čije su korelacije prikazane na toplotnoj mapi (Slika 22). Dvanaesto pitanje (Osećam nervozu) i sedamnaesto pitanje (Zabrinut sam) imala su jaku povezanost (0,7, što je najbliža vrednost +1).

Pored toga, 10. pitanje (osećam se prijatno) i pitanje 15 (opušten sam) imali su prihvatljive korelacije sa iznosom od 0,6. Među ovim pitanjima, 20.: pitanje (osećam se ugodno) imalo je veliki uticaj na korelaciju sa ostalim pitanjima iz upitnika, što znači da, iako su studentkinje imale nekih briga tokom studija, bilo je razloga da su se osećale ugodno. Na kraju, Slika 22 je pokazala najbolji odnos između ukupnih rezultata anksioznosti stanja i pitanja iz dela upitnika o stanju anksioznosti.

Da bi se rezimirali ključni nalazi ove studije i napravio odnos između njih i istraživačkih pitanja, treba napomenuti da je odvajanje roda radi boljeg razlikovanja stresa i anksioznosti uspelo smanjiti pogrešku linearnim regresionim algoritmom, prema Tabeli 14.

Ova metodologija kao prihvatljiv vodič za istraživače u oblasti pametne zdravstvene zaštite bila je odgovarajući način da se odluči o stresu ili anksioznosti jednog pola, jer njihovo ponašanje nije prijavljeno kao isto [175], [176]. Pored toga, i kao što je objašnjeno u pregledu literature, Kim i saradnici [142] su tvrdili da bi fokusiranje na razdvajanje starosti i pola moglo imati neke koristi na rezultate i detekciju stresa i anksioznosti kod mlađih odraslih osoba.

Na odgovor na drugo istraživačko pitanje koje je u poglavlju metodologije istraživanja uvedeno o pušenju, fizičkoj aktivnosti i prosečnoj oceni tokom studiranja vezanom za stres i anksioznost među studentkinjama i smanjenju stope greške linearног regresionог algoritма, treba napomenuti da je faza nakon intervencije koja koristi karakteristike u analizi pokazala najbolje performanse u odnosu na fazu pre intervencije.

Kao što su tvrdili prethodni nalazi istraživanja, ove karakteristike su bile povezane sa stresom ili anksioznošću studentkinja, a efekat ovih slučajeva na smanjenje ekstrakcije grešaka bio je očigledan [11], [43], [45]– [47]. Štaviše, rezultati istraživanja su pokazali da je izvlačenje karakteristika ponašanja studenata bila jedno od ograničenja studije [35], tako da je ovo istraživanje pokrilo neke važne ključne faktore u tom pogledu.

Kao što je pomenuto u pregledu literature, Jia i Vang [139] su prijavili neke poteškoće u prikupljanju različitih vrsta informacija o anksioznosti učenika u školi, a prema Huang i koautorima [141] i Kim i koautorima [142] koji su tvrdili da su različiti izvori anksioznosti učenika ili uzorci podataka nedovoljni. Naša studija je koristila prihvatljiv skup podataka za ovaj cilj.

Tako su rezultati pokazali da je i jaz u pregledu literature rešen. Ova studija je koristila klaster analizu kako bi identifikovala stres i anksioznost među studentkinjama, pa čak i pojedinačno sa većim rizikom prema njihovim karakteristikama na univerzitetu. Dva klastera učesnika identifikovana su na osnovu njihovih karakteristika i ukupnih rezultata anksioznosti stanja (target). U osnovi, na ovom pitanju se insistira na klaster analizi. U klasteru 1, studenti su iskusili visok nivo anksioznosti zbog najveće stope pušenja i najniže stope fizičke aktivnosti. Sa druge strane, Klaster 2, oblast visokog nivoa anksioznosti je prikazan kao nizak jer je pušenje cigareta niže nego u Klasteru 1, a fizičke aktivnosti studentkinja su takođe na visokom nivou.

Pored ovih karakteristika, jer je prosečna ocena tokom studiranja bila prilična slična, treba pribeležiti da su takvi rezultati razumni. Na kraju, klaster analiza koristeći *k-means* algoritam naglašava da ova tri ključna faktora imaju uticaj na stres i anksioznost kod studentkinja. Konačno, takav skup podataka koristi tri ključna faktora na osobine ponašanja studenata koje pozitivno utiču na naš model, pa ovo može biti ispitano na visokom nivou sa raznim skupovima podataka.

## 7. Naučni i stručni doprinosi

Cilj ovog istraživanja i doktorske disertacije bio je da istraži analizu glavnih izazova izvučenih iz literature u prethodnim studijama. Glavni izazovi i nedostaci ovog istraživanja uključuju:

- ✚ Predviđanje i otkrivanje stresa i anksioznosti studentkinja, zajedno sa 3 važna ključna faktora kao što su stopa pušenja, fizička aktivnost i njihova prosečna ocena tokom studiranja pomoću algoritama i funkcija mašinskog učenja.
- ✚ Pronalaženje faktora sa najvećim uticajem korišćenjem metode regresione analize (LASSO) na anksioznost stanja i osobina nakon treninga bio je jedan od vitalnih praznina u ovom istraživanju.
- ✚ Nedostataka u literaturi (tabela 3).

Pored ovih pitanja, glavna istraživačka pitanja uključuju:

- ✚ Da li je odvajanje roda radi boljeg razlikovanja stresa i anksioznosti u stanju da smanji grešku sa linearnim regresionim algoritmom?
- ✚ U kojoj meri se mogu dodati ključne karakteristike (pušenje, fizička aktivnost i prosečna ocena tokom studiranja) koji se odnose na stres i anksioznost među studentkinjama smanjiti stopu greške linearog regresionog algoritma?

Naučni doprinos ove disertacije uključuje:

- ✚ Analizu mogućnosti primene usluga pametne zdravstvene zaštite zasnovanih na AI algoritmima i funkcijama.
- ✚ Analiza primenjivosti korišćenih alata i metoda za usluge pametne zdravstvene zaštite i razvoj modela.
- ✚ Analiza ključnih karakteristika ponašanja vezanih za stres studentkinja pomoću alata mašinskog učenja.

Detaljnije, naučni doprinosi odnose se na:

- ✚ **Proširenje znanja:** Ovo istraživanje unapređuje razumevanje predviđanja stresa i anksioznosti kod svih studenata u skupovima podataka, kao i stresa i anksioznosti studentkinja korišćenjem algoritama i funkcija mašinskog učenja, rešavajući nedostatke identifikovane u prethodnim studijama.
- ✚ **Metodološki napredak:** Rešavanje izazova u predviđanju i otkrivanju stresa i anksioznosti primenom mašinskog učenja i integriranjem faktora ponašanja kao što su pušenje, stopa fizičke aktivnosti i prosečna ocena tokom studiranja, i korišćenjem linearne regresije za predviđanja visoke tačnosti.
- ✚ **Empirijski podaci:** Analizirana anksioznost stanja i anksioznost osobina kod 231 studenta u visokom obrazovanju, otkrivajući ključne metrike kao što su srednja apsolutna greška, srednja kvadratna vrednost i faktori sa najvećim uticajem preko funkcije LASSO. Pored toga, u drugom delu su analizirani

samo podaci o stresu i anksioznosti studentkinja korišćenjem linearne regresije i klaster analize.

- ⊕ **Overfitting i Underfitting:** Pokazali su minimalne probleme u predviđanjima stanja i osobina anksioznosti koristeći *KNN* algoritme.

### Stručni doprinosi:

- ⊕ **Praktične primene u pametnoj zdravstvenoj zaštiti:** rešavanje problema u pametnoj zdravstvenoj zaštiti primenom *AI* algoritama, kao i funkcija za otkrivanje stresa i anksioznosti, posebno kod studentkinja.
- ⊕ **Rodno specifični uvidi:** Odvojeni podaci po polu za poboljšanje tačnosti detekcije anksioznosti, identifikovanjem visoko rizičnih podgrupa koristeći *k-means* algoritma klasterovanja.
- ⊕ **Smanjenje grešaka:** Postignuto značajno smanjenje grešaka nakon intervencije i istaknuta važnost upotrebe alata za mašinsko učenje kao što su toplotne mape za korelacionu analizu.
- ⊕ **Unapređenje metodologije:** Razvijena je robusna metodologija za otkrivanje i predviđanje stresa i anksioznosti, sa praktičnim implikacijama za akademske i industrijske primene, obuhvatajući:
  - Novi okvir razvijen za otkrivanje stresa ili anksioznosti među studentima koristeći *AI* metode i alate.
  - U ovom istraživanju obrađeni su kooperativni modeli prikupljanja, pohrane, analize i preporuke podataka.
  - Poboljšanje algoritma za procenu stresa i anksioznosti studentkinja korišćenjem povezanih atributa kao što su pušenje cigareta, prosečna ocena tokom studiranja, fizičke aktivnosti.
  - Kvantitativna procena osnovnih klasifikatora koji povezuju ključne karakteristike kao što su pušenje cigareta, prosečna ocena tokom studiranja, fizičke aktivnosti sa simptomima svakog ciljnog stanja.
  - Razvoj smernica za obrazovne institucije, bolnice i klinike kako bi se poboljšali dobri mentalni uslovi za studente.
  - Smanjenje grešaka u detekciji stresa ili anksioznosti za profesionalce u akademskim i industrijskim oblastima.
  - Određivanje mogućnosti modela za adaptivnu detekciju anksioznosti na osnovu *AI* metoda.
  - Analiza algoritama i funkcija mašinskog učenja za implementaciju modela za otkrivanje faktora sa visokim uticajem na stres ili anksioznost studenata na univerzitetu.
  - Uvođenje novih stručnih funkcija i rešenja u kontekstu analize podataka i na osnovu skupova podataka o stresu i anksioznosti učenika.

Ovo istraživanje ne samo da poboljšava teorijsko znanje, već pruža i praktična rešenja i metodologije koje se mogu primeniti u obrazovnim i zdravstvenim ustanovama radi boljeg

predviđanja i upravljanja studentskim stresom i anksioznošću, posebno među studentkinjama.

Najznačajniji društveni doprinosi rezultata istraživanja su:

- ⊕ Poboljšanje opuštajuće atmosfere među studentima, posebno studentkinjama na univerzitetu, pa čak i u društvu.
- ⊕ Poboljšanje razmene povratnih informacija i saradnje između studenata i predavača na univerzitetu, kao i saradnje između studenata.
- ⊕ Alternativni model za pružanje pametnog zdravstvenog sistema i usluga za studente i nastavnike, društvenu interakciju i profesionalni razvoj.
- ⊕ Određivanje modela efikasnosti u detekciji stresa ili anksioznosti kod studentkinja na osnovu reakcije u realnom vremenu pomoću AI algoritama i funkcija.
- ⊕ Poboljšanje profesionalnih i akademskih performansi i društvenih odnosa između studenata.
- ⊕ Identifikovanje žena sa rizikom od depresije.

Konačno, sledeći istraživački članci objavljeni su tokom istraživanja sprovedenih u ovoj doktorskoj disertaciji:

1. **Lotfi, F.**, Rodić, B., Labus, L., & Bogdanović, Z., (2024), "Smart healthcare: developing a pattern to predict the stress and anxiety among university students using machine learning technology", Journal of Universal Computer Science, vol. 30, no. 10 (2024), 1316-1342. DOI:10.3897/jucs.116174. M23
2. **Lotfi, F.**, Rodić, B., & Bogdanović, Z. (2022, June). A System For Monitoring And Managing The Anxiety Among The Young People Using Machine Learning. In E-business technologies conference proceedings (Vol. 2, No. 1, pp. 91-94). M33
3. Khadivar, A., Ghale, P. H., & **Lotfi, F.** (2024). A Model to Accepting the Internet of Things by Health Managers in Iran: A Mixed Approach. International Journal of Computer Information Systems and Industrial Management Applications, 16(1), 16-16. M50
4. A. Atighehchian, T. Alidadi, R. R. Mohammadi, **F. Lotfi**, S. Ajami., "Identifying the Application of Process Mining Technique to Visualise and Manage in the Healthcare Systems." In International Conference on Computer Science, Engineering and Education Applications, pp. 299-308. Cham: Springer Nature Switzerland, 2023. M33
5. **F. Lotfi** and M. Mansourifard, "Introducing a Model for Customer Satisfaction Based Smart Business Systems". E-Business Technologies Conference Proceedings, 1(1), 25–30. Retrieved from <https://ebt.rs/journals/index.php/conf-proc/article/view/26>. (2021). M33
6. **F. Lotfi** and B. Rodić, & Z. Bogdanović, "A System For Monitoring And Managing The Anxiety Among The Young People Using Machine Learning". E-Business Technologies Conference Proceedings, 2(1), 91–94. Retrieved from <https://ebt.rs/journals/index.php/conf-proc/article/view/96>, 2022, June. M33

## 8. Budući rad

Istraživači u budućnosti mogu pratiti predloge u nastavku:

- ⊕ Buduća istraživanja mogu ispitati količinu više karakteristika ponašanja u glavnom modelu koristeći algoritme i funkcije dubokog učenja (u dva dela, prvo bez ispitivanja takvih karakteristika sa glavnim standardnim upitnikom *STAI* i drugim, analizom podataka o stresu i anksioznosti sa ovim karakteristikama i više faktora u ovoj oblasti).
- ⊕ Istraživači takođe mogu analizirati karakteristike stresa i anksioznosti drugih studenata kako bi ih uporedili sa karakteristikama ponašanja.
- ⊕ Buduće studije takođe mogu koristiti prethodne zapise o anksioznosti i neke probleme poput nesanice i analizirati ih pomoću metoda dubokog učenja. Istraživači se takođe mogu fokusirati na zagađenje vazduha i njegove efekte na anksioznost studenata koristeći metode dubokog učenja.
- ⊕ Buduća istraživanja mogu koristiti *API-je* i onlajn baze podataka kao što su *Google Health Studies AP*, kao i *SZO* sa raznim ogromnim skupovima podataka koji koriste algoritme dubokog učenja da izdvoje najdublje uticaje i veze u pogledu analiziranih podataka.
- ⊕ Izvlačenje podataka o stresu i anksioznosti studenata pomoću nosivih uređaja kao što su *Apple* sat, pametni bendovi i *Fitbit*, kao i drugi prikupljeni biometrijski podaci zajedno sa karakteristikama i analiza primenom algoritma mašinskog i dubokog učenja.

Prema nalazima ovog istraživanja, budući radovi mogu se fokusirati na više karakteristika povezanih sa anksioznošću studentkinja korišćenjem mašinskog učenja, kao i tehnika dubokog učenja.

## 9. Zaključak

Trenutno istraživanje objašnjava kako nalazi ove studije mogu proširiti znanje stručnjaka u predviđanju stresa i anksioznosti studenata koristeći *AI* tehnologiju. Prema izazovima predviđanja anksioznosti među studentima pomoću mašinskog učenja prikazanim u Tabeli 2, neki od njih su izabrani kao jaz u ovoj studiji i rešeni su. U stvari, ovo istraživanje je imalo za cilj da izvuče duboke informacije i detalje o studentima, kao i neke karakteristike ponašanja poput pušenja, prosečne ocene tokom studiranja i stope fizičke aktivnosti proverom njihovih konačnih rezultata anksioznosti. Zatim, koristeći linearnu regresiju, dokazano je da se takvi podaci mogu predvideti sa najvećom tačnošću pomoću nadgledanog algoritma učenja. Analiza podataka otkriva anksioznost stanja i osobina 231 studenta u visokom obrazovanju sa metrikom grešaka. Analiza podataka je takođe pokazala *MAE* i *MSE* ovih faktora i odnos između njih, kao i funkciju *LASSO*, koja je identifikovala osnovne faktore sa najvećim uticajem nakon treninga. Štaviše, prekomerna i nedovoljna prilagođenost *KNN* pokazuje najniže probleme u anksioznosti stanja, posebno u anksioznosti osobina. U ovom istraživanju, neke zabrinutosti su takođe adekvatno rešene u kontekstu pametne zdravstvene zaštite u tom pogledu. Konačno, predstavljeni istraživački pristup može imati nekoliko praktičnih koncepta u akademskoj i industrijskoj oblasti [177].

Da bi se zaključio drugi deo studije, odvajanje roda za otkrivanje anksioznosti pomoću tehnologije mašinskog učenja odabранo je za prihvatljive performanse sa velikim uticajem. Konkretno, povezani faktori ili karakteristike stresa ili anksioznosti studenata mogu imati pozitivan uticaj na rezultate, kao i smanjene greške.

Alati za učenje kao što je toplotna mapa izvukli su korelaciju između dve promenljive i između najmanjeg uticaja i najvećeg uticaja.

Stopa grešaka, kao i niske greške posebno posle intervencije u poređenju sa pre intervencije, bili su značajan zaključak ovog istraživanja. Uprkos ovim obzirima, ovo istraživanje je koristilo analizu klastera upotrebom *k-means* algoritma da identificuje podgrupu anksioznosti studentkinja sa visokim rizikom. Mi smo bili u stanju da uvedemo visoko-kvalitetnu metodologiju u pametni zdravstveni sistem i sudeći po detekciji stresa i anksioznosti kod studentkinja koristeći algoritme veštačke inteligencije.

Najznačajniji skup podataka o anksioznosti stanja sa srodnim ključnim karakteristikama kodiran je kako bi se smanjile greške koristeći višestruku linearnu regresiju. Iako nije bilo problema u linearnoj regresionoj analizi korišćenjem skupa podataka, a stopa grešaka je ekstrahovana sa visokom tačnošću i performansama, ova studija je pokazala da će sa više studenata biti najbolje karakteristike u klaster analizi.

Na kraju, klaster analiza je pokazala da je za otkrivanje stresa studentkinja korišćenjem algoritama mašinskog učenja sa najvišim nivoom tačnosti potrebno više karakteristika vezanih za stres i anksioznost studentkinja.

## 9.1. Prednosti

Najznačajnije prednosti realizovanog istraživanja uključuju:

- ⊕ **Rana intervencija:** Veštačka inteligencija može omogućiti rano otkrivanje i predviđanje indikatora stresa, omogućavajući obrazovnim institucijama da pruže pravovremenu podršku i intervencije.
- ⊕ **Personalizacija:** Analizirajući, procenjujući i prateći podatke o stresu i anksioznosti studenata, tehnologija mašinskog učenja može personalizovati intervencije na osnovu jedinstvenih obrazaca stresa svakog studenta.
- ⊕ **Optimizacija resursa:** Institucije mogu efikasnije alocirati resurse ciljanjem podrške tamo gde je najpotrebnija.
- ⊕ **Poboljšana tačnost i pouzdanost:** Ova studija je uspela poboljšati tačnost i pouzdanost usluga pametne zdravstvene zaštite kako bi se poboljšalo otkrivanje i predviđanje stresa i anksioznosti studenata u kontekstu tehnologije mašinskog učenja.
- ⊕ **Komplementarni podaci:** *STAI* može pružiti vredne podatke o fazama stresa i anksioznosti studentkinja, *biofeedback* nudi objektivne fiziološke podatke u stvarnom vremenu. Kombinacija oba ova problema može poboljšati tačnost i pouzdanost modela.
- ⊕ **Validacija:** *Biofeedback* može potvrditi podatke koje su sami prijavili u ovoj studiji. Na primer, fiziološki odgovori mogu potvrditi prijavljene nivoane anksioznosti, pružajući sveobuhvatnije razumevanje.

Konačno, ova tehnologija ima potencijal da se integriše u nosive uređaje, čineći je dostupnom i pogodnom za svakodnevnu upotrebu. Kao aplikacija koja bi mogla biti kodirana za ovo istraživanje i koja će biti instalirana na pametnom telefonu, ona kontinuirano prikuplja podatke, pokreće ih kroz algoritme mašinskog učenja i pruža trenutne povratne informacije i preporuke. Ova petlja *biofeedbacka* u realnom vremenu može značajno poboljšati sposobnost mladog studenta da upravlja stresom.

## 9.2. Ograničenja istraživanja

U ovoj studiji bilo je nekoliko ograničenja:

- ⊕ Ispitni period je bio jedno od ograničenja ove studije jer studenti nisu imali dovoljno vremena i fokusa da popune onlajn upitnik. Jedan od ograničenja ovog istraživanja bilo je vreme prikupljanja podataka među fakultetima Univerziteta u Beogradu, koje se poklopilo sa ispitnim rokom za polaznike između 2021. i 2022. godine. Tokom ovog perioda, studenti su verovatno bili zaokupljeni učenjem i polaganjem ispita. Ovaj period visokog stresa značio je da učesnici možda nisu imali dovoljno vremena ili mentalnog fokusa da pažljivo i temeljno popune onlajn upitnik. Shodno tome,

odgovori prikupljeni tokom ovog perioda možda neće tačno odražavati njihova istinska mišljenja ili iskustva, što potencijalno utiče na pouzdanost i validnost nalaza studije.

- ⊕ Pored toga, najvažnije ograničenje ovog istraživanja je nedostatak znanja engleskog jezika kod studenata. Neki od studenata koji su učestvovali u studiji nisu imali dovoljno znanja engleskog jezika. To se posebno pokazalo među nekim od studenata osnovnih studija na Medicinskom fakultetu i Stomatološkom fakultetu, koji su bili na studijskom programu srpskog jezika na svom fakultetu. Njihova ograničena sposobnost razumevanja, čitanja ili pisanja na engleskom jeziku možda je uticala na njihovo učešće u istraživanju, tačnost njihovih odgovora i ukupan kvalitet podataka. Shodno tome, ova jezička barijera pojavila se kao kritično ograničenje, potencijalno utičući na valjanost i pouzdanost nalaza istraživanja.

Takođe, nakon predprocesiranja, shvaćeno je da neki od ispitanika nisu bili u mogućnosti da daju tačne odgovore zbog nedostatka samosvesti i sličnih razloga.

## 10. Dodatak A.

Sve stavke su ocenjivane na četvorostepenoj Likertovoj skali za stanje anksioznosti (1 - "uopšte ne", 2 - "donekle", 3 - "umereno", i 4 - "veoma"), a takođe je korišćena i četvorostepena Likertova skala za osobinu anksioznosti koja je sledeća: (1 - "gotovo nikada", 2 - "ponekad", 3 - "često", 4 - "gotovo uvek").

Ne.	Glavna pitanja – Anksioznost države	Skaliranje			
		1	2	3	4
1	Osećam se smireno.	12.6%	35.5%	34.2%	17.7%
2	Osećam se sigurno.	12.6%	26.4%	32.9%	28.1%
3	Napeta sam.	15.6%	45.9%	24.2%	14.3%
4	Osećam se napeto.	27.3%	41.1%	24.2%	7.4%
5	Osećam se lako.	18.2%	39%	32%	10.8%
6	Osjećam se uz nemireno.	27.7%	46.8%	20.3%	5.2%
7	Trenutno se brinem zbog mogućih nesreće.	22.9%	39.4%	19.5%	18.2%
8	Osećam se zadovoljno.	13.4%	37.7%	31.2%	17.7%
9	Osećam se uplašeno.	40.3%	41.6%	11.7%	6.4%
10	Osećam se ugodno.	9.1%	31.2%	39%	20.7%
11	Osećam se samouvereno.	14.3%	26.4%	39%	20.3%
12	Osećam se nervozno.	16.9%	47.6%	20.8%	14.7%
13	Ja sam nervozan.	32%	45.9%	15.6%	6.5%
14	Osećam se neodlučno.	24.7%	45%	19.9%	10.4%
15	Ja sam opušten.	16.9%	31.2%	35.9%	16%
16	Osećam se zadovoljno.	14.3%	40.3%	35.1%	10.3%
17	Zabrinut sam.	21.2%	41.6%	26%	11.2%
18	Osećam se zbumjeno.	29.9%	44.2%	18.6%	7.3%
19	Osećam se mirno.	18.6%	39.8%	29.4%	12.2%
20	Osećam se ugodno.	11.7%	37.2%	36.4%	14.7%
Ne.	Glavna pitanja – Anksioznost	1	2	3	4
21	Osećam se ugodno.	9.9%	41.6%	37.2%	11.3%
22	Osećam se nervozno i nemirno.	12.6%	59.7%	19.9%	7.8%
23	Zadovoljan sam sobom.	13%	37.2%	32.9%	16.9%
24	Voleo bih da mogu da budem srećna kao što drugi izgledaju biti.	31.5%	39%	16.5%	13%
25	Osećam se kao neuspeh.	43.3%	40.7%	10.8%	5.2%
26	Osećam se odmorno.	20.8%	49.8%	20.8%	8.6%
27	Ja sam "smiren, cool i opušten".	15.6%	41.6%	28.1%	14.7%
28	Osećam da se teškoće gomilaju tako da ne može da ih prevaziđe.	24.7%	53.7%	14.7%	6.9%
29	Previše se brinem zbog nečega što stvarno nije bitno.	15.2%	40.7%	22.5%	21.6%
30	Ja sam srećan.	6.1%	28.1%	34.2%	31.6%
31	Imam uz nemirujuće misli.	26.4%	45%	20.3%	8.3%
32	Nedostaje mi samopouzdanja.	24.7%	45.9%	17.3%	12.1%

33	Osećam se sigurno.	10.8%	35.1%	29.4%	24.7%
34	Lako donosim odluke.	12.6%	40.7%	36.8%	9.9%
35	Osećam se neadekvatno.	26.8%	51.5%	18.2%	3.5%
36	Ja sam zadovoljan.	9.1%	49.4%	27.7%	13.8%
37	Neka nevažna misao prolazi kroz pameti i smeta mi.	15.2%	49.4%	22.9%	12.5%
38	Uzimam razočarenja kroz koja prolazi misao pameti i smeta mi.	18.6%	48.5%	22.5%	10.4%
39	Ja sam stabilna osoba.	10%	46.3%	27.7%	16%
40	Ja se nalazim u stanju tenzije ili previranja kad razmišljam o mojim nedavnim brigama i interesima.	19.9%	48.5%	22.1%	9.5%

## 11. Reference

- [1] S. Barton, C. Karner, F. Salih, D. S. Baldwin, and S. J. Edwards, ‘Clinical effectiveness of interventions for treatment-resistant anxiety in older people; a systematic review’, *Health Technology Assessment*, vol. 18, no. 50, pp. 1–60, 2014.
- [2] N. M. Stojanović *et al.*, ‘Reliability and validity of the Spielberger’s state-trait anxiety inventory (STAI) in Serbian university student and psychiatric non-psychotic outpatient populations’, *Acta Facultatis Medicinae Naissensis*, vol. 327, no. 2, pp. 149–159, 2020, doi: 10.5937/afmnai37-25011.
- [3] E. W. McGinnis *et al.*, ‘Giving Voice to Vulnerable Children: Machine Learning Analysis of Speech Detects Anxiety and Depression in Early Childhood’, *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 6, pp. 2294–2301, Nov. 2019, doi: 10.1109/JBHI.2019.2913590.
- [4] C. D. Spielberger, F. Gonzalez-Reigosa, A. Martinez-Urrutia, L. F. S. Natalicio, and D. S. Natalicio, ‘The state-trait anxiety inventory’, *Revista Interamericana de Psicología/Interamerican Journal of Psychology*, vol. 5, no. 3 & 4, 1971.
- [5] H. Huang and K. Wan, ‘Heart rate variability in junior high school students with depression and anxiety in Taiwan’, *Acta neuropsychiatrica*, vol. 25, no. 3, pp. 175–178, 2013.
- [6] A. Sau and I. Bhakta, ‘Predicting anxiety and depression in elderly patients using machine learning technology’, *Healthcare Technology Letters*, vol. 4, no. 6, pp. 238–243, 2017, doi: 10.1049/htl.2016.0096.
- [7] C. L. van Vuuren *et al.*, ‘Comparing machine learning to a rule-based approach for predicting suicidal behavior among adolescents: Results from a longitudinal population-based survey’, *Journal of Affective Disorders*, vol. 295, pp. 1415–1420, 2021, doi: 10.1016/j.jad.2021.09.018.
- [8] A. Labus, B. Radenković, B. Rodić, D. Barać, and A. Malešević, ‘Enhancing smart healthcare in dentistry: an approach to managing patients’ stress’, *Informatics for Health and Social Care*, vol. 46, no. 3, pp. 306–319, 2021, doi: 10.1080/17538157.2021.1893322.
- [9] N. Valle, P. Antonenko, D. Valle, K. Dawson, A. C. Huggins-Manley, and B. Baiser, ‘The influence of task-value scaffolding in a predictive learning analytics dashboard on learners’ statistics anxiety, motivation, and performance’, *Computers and Education*, vol. 173, Nov. 2021, doi: 10.1016/j.compedu.2021.104288.
- [10] F. M. Delpino *et al.*, ‘Prevalence of anxiety during the COVID-19 pandemic: A systematic review and meta-analysis of over 2 million people’, *Journal of Affective Disorders*, vol. 318, pp. 272–282, Dec. 2022, doi: 10.1016/j.jad.2022.09.003.
- [11] O. Hahad *et al.*, ‘The association of smoking and smoking cessation with prevalent and incident symptoms of depression, anxiety, and sleep disturbance in the general population’, *Journal of Affective Disorders*, vol. 313, pp. 100–109, Sep. 2022, doi: 10.1016/j.jad.2022.06.083.
- [12] H. Liu, X. Liu, and W. Xu, ‘Prevalence and influencing factors of anxiety in medical students during the COVID-19 pandemic’, *Heliyon*, vol. 8, no. 9, p. e10487, Sep. 2022, doi: 10.1016/j.heliyon.2022.E10487.
- [13] L. P. Jiménez-Mijangos, J. Rodríguez-Arce, R. Martínez-Méndez, J. Javier Reyes-Lagos, and J. Javier Reyes-Lagos contributed equally, ‘Education and Information Technologies Advances and challenges in the detection of academic stress and anxiety in the classroom: A literature review and recommendations’, *Education and Information Technologies*, 123AD, doi:

10.1007/s10639-022-11324-w.

- [14] Z. Nuryana, W. Xu, L. Kurniawan, N. Sutanti, S. A. Makruf, and I. Nurcahyati, ‘Student stress and mental health during onlajn learning: Potential for post-COVID-19 school curriculum development’, *Comprehensive Psychoneuroendocrinology*, vol. 14, p. 100184, May 2023, doi: 10.1016/J.CPNEC.2023.100184.
- [15] N. A. Balogun, F. A. Adeleke, M. D. Abdulrahaman, Y. I. Shehu, and A. Adedoyin, ‘Undergraduate students’ perception on e-learning systems during COVID-19 pandemic in Nigeria’, *Heliyon*, vol. 9, no. 3, p. e14549, Mar. 2023, doi: 10.1016/J.HELION.2023.E14549.
- [16] H. Liu, H. Peng, X. Song, C. Xu, and M. Zhang, ‘Using AI chatbots to provide self-help depression interventions for university students: A randomized trial of effectiveness’, *Internet Interventions*, vol. 27, p. 100495, Mar. 2022, doi: 10.1016/J.INVENT.2022.100495.
- [17] M. K. Al-Medfa, A. M. S. Al-Ansari, A. H. Darwish, T. A. Qreeballa, and H. Jahrami, ‘Physicians’ attitudes and knowledge toward artificial intelligence in medicine: Benefits and drawbacks’, *Heliyon*, vol. 9, no. 4, p. e14744, Apr. 2023, doi: 10.1016/J.HELION.2023.E14744.
- [18] H. Alharthi, ‘Predicting the level of generalized anxiety disorder of the coronavirus pandemic among college age students using artificial intelligence technology’, in *Proceedings - 2020 19th Distributed Computing and Applications for Business Engineering and Science, DCABES 2020*, Oct. 2020, pp. 218–221. doi: 10.1109/DCABES50732.2020.00064.
- [19] A. Ahmed, R. Sultana, M. T. R. Ullas, M. Begom, M. M. I. Rahi, and M. A. Alam, ‘A Machine Learning Approach to detect Depression and Anxiety using Supervised Learning’, Dec. 2020. doi: 10.1109/CSDE50874.2020.9411642.
- [20] D. Mannapperuma and A. Kirupananada, ‘ADAM- Anxiety Detection and Management: a Solution to Manage Anxiety at Workplaces and Improve Productivity’, in *Proceedings of 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2020*, Dec. 2020, pp. 243–246. doi: 10.1109/WIECON-ECE52138.2020.9397932.
- [21] T. Richter, B. Fishbain, E. Fruchter, G. Richter-Levin, and H. Okon-Singer, ‘Machine learning-based diagnosis support system for differentiating between clinical anxiety and depression disorders’, *Journal of Psychiatric Research*, vol. 141, pp. 199–205, Sep. 2021, doi: 10.1016/j.jpsychires.2021.06.044.
- [22] K. Hueniken *et al.*, ‘Machine learning–based predictive modeling of anxiety and depressive symptoms during 8 months of the COVID-19 global pandemic: Repeated cross-sectional survey study’, *JMIR mental health*, vol. 8, no. 11, p. e32876, 2021.
- [23] U. S. Reddy, A. V. Thota, and A. Dharun, ‘Machine learning techniques for stress prediction in working employees’, in *2018 IEEE International Conference on Computational Intelligence and Computing Research (ICCI)*, 2018, pp. 1–4.
- [24] L. G. Tennenhouse, R. A. Marrie, C. N. Bernstein, and L. M. Lix, ‘Machine-learning models for depression and anxiety in individuals with immune-mediated inflammatory disease’, *Journal of Psychosomatic Research*, vol. 134, Jul. 2020, doi: 10.1016/J.JPSYCHORES.2020.110126.
- [25] A. Pittig, J. Hoyer, and R. Noack, ‘Smart-glass guided exposure for anxiety disorders: a proof-of-concept study’, *Cognitive and Behavioral Practice*, vol. 28, no. 3, pp. 364–378, 2021.
- [26] K. Conroy *et al.*, ‘Harnessing Home-School Partnerships and School Consultation to Support Youth With Anxiety’, *Cognitive and Behavioral Practice*, vol. 29, no. 2, pp. 381–399, May 2022, doi: 10.1016/J.CBPRA.2021.02.007.

- [27] B. Niusha, A. Farghadani, and N. Safari, ‘Effects of Assertiveness Training on Test Anxiety of Girl Students in First Grade of Guidance School’, *Procedia - Social and Behavioral Sciences*, vol. 46, pp. 1385–1389, Jan. 2012, doi: 10.1016/J.SBSPRO.2012.05.307.
- [28] A. E. Mercado *et al.*, ‘Mental health diagnoses in hospitalized adults with congenital heart disease in the state of Texas: A 10-year review’, *International Journal of Cardiology Congenital Heart Disease*, vol. 7, p. 100340, Mar. 2022, doi: 10.1016/J.IJCCHD.2022.100340.
- [29] P. Stute and S. Lozza-Fiacco, ‘Strategies to cope with stress and anxiety during the menopausal transition’, *Maturitas*, vol. 166, pp. 1–13, Dec. 2022, doi: 10.1016/J.MATURITAS.2022.07.015.
- [30] D. S. Natalicio, ‘Development of the Spanish edition of the state-trait anxiety inventory’, *Interamerican Journal of Psychology*, vol. 5, pp. 145–158, 1971.
- [31] B. G. Dias, S. B. Banerjee, J. V. Goodman, and K. J. Ressler, ‘Towards new approaches to disorders of fear and anxiety’, *Current Opinion in Neurobiology*, vol. 23, no. 3, pp. 346–352, Jun. 2013, doi: 10.1016/J.CONB.2013.01.013.
- [32] J. Li and J. S. Huang, ‘Dimensions of artificial intelligence anxiety based on the integrated fear acquisition theory’, *Technology in Society*, vol. 63, p. 101410, Nov. 2020, doi: 10.1016/J.TECHSOC.2020.101410.
- [33] A. Priya, S. Garg, and N. P. Tigga, ‘Predicting Anxiety, Depression and Stress in Modern Life using Machine Learning Algorithms’, in *Procedia Computer Science*, 2020, vol. 167, pp. 1258–1267. doi: 10.1016/j.procs.2020.03.442.
- [34] D. Soysal, M. Bani-Yaghoub, and T. A. Riggers-Piehl, ‘A Machine Learning Approach to Evaluate Variables of Math Anxiety in STEM Students’, *Pedagogical Research*, vol. 7, no. 2, p. em0125, 2022, doi: 10.29333/pr/11978.
- [35] R. Qasrawi, S. P. Vicuna Polo, D. Abu Al-Halawa, S. Hallaq, and Z. Abdeen, ‘Assessment and Prediction of Depression and Anxiety Risk Factors in Schoolchildren: Machine Learning Techniques Performance Analysis’, *JMIR Formative Research*, vol. 6, no. 8, p. e32736, Aug. 2022, doi: 10.2196/32736.
- [36] M. L. Tlachac, M. Reisch, B. Lewis, R. Flores, L. Harrison, and E. Rundensteiner, ‘Impact assessment of stereotype threat on mobile depression screening using Bayesian estimation’, *Healthcare Analytics*, vol. 2, p. 100088, Nov. 2022, doi: 10.1016/J.HEALTH.2022.100088.
- [37] A. H. Weinberger, M. Gbedemah, A. M. Martinez, D. Nash, S. Galea, and R. D. Goodwin, ‘Trends in depression prevalence in the USA from 2005 to 2015: widening disparities in vulnerable groups’, *Psychological Medicine*, vol. 48, no. 8, pp. 1308–1315, Jun. 2018, doi: 10.1017/S0033291717002781.
- [38] F. Bakul and E. Z. Heanoy, ‘Impact of COVID-19 anxiety on loneliness and sleep quality of students and professionals in Bangladesh’, *Acta Psychologica*, vol. 230, p. 103759, Oct. 2022, doi: 10.1016/J.ACTPSY.2022.103759.
- [39] M. M. Rahman *et al.*, ‘Assessing the psychological condition among general people of Bangladesh during COVID-19 pandemic’, *Journal of Human Behavior in the Social Environment*, vol. 31, no. 1–4, pp. 449–463, 2021, doi: 10.1080/10911359.2020.1848688.
- [40] R. Naiem, J. kaur, S. Mishra, and A. Saxena, ‘Impact of COVID-19 Pandemic on Mental Health Using Machine Learning and Artificial Intelligence’, pp. 263–274, 2022, doi: 10.1007/978-981-16-2594-7\_21.
- [41] D. Brathwaite *et al.*, ‘Age and sex trends among mental health-related emergency department visits in North Carolina’, *Healthcare Analytics*, vol. 2, p. 100056, Nov. 2022, doi: 10.1016/J.HEALTH.2022.100056.

- [42] K. L. Lavallee, X. C. Zhang, S. Schneider, and J. Margraf, ‘A longitudinal examination of the relationship between smoking and panic, anxiety, and depression in Chinese and German students’, *Addictive Behaviors Reports*, vol. 14, p. 100347, 2021, doi: 10.1016/j.abrep.2021.100347.
- [43] B. Rekabdar, D. Albright, J. McDaniel, S. Talafha, and H. Jeong, ‘From machine learning to deep learning: A comprehensive study of alcohol and drug use disorder’, *Healthcare Analytics*, p. 100104, Nov. 2022, doi: 10.1016/J.HEALTH.2022.100104.
- [44] M. N. Wanjau *et al.*, ‘Physical activity and depression and anxiety disorders in Australia: a lifetable analysis’, *AJPM Focus*, p. 100030, Sep. 2022, doi: 10.1016/J.FOCUS.2022.100030.
- [45] M. Short, K. Martin, L. Livingston, and P. Côté, ‘Physical activity, sedentary behaviour and symptoms of anxiety in post-secondary students: A cross-sectional study of two faculties’, *Psychiatry Research Communications*, vol. 1, no. 1, p. 100007, Oct. 2021, doi: 10.1016/J.PSYCOM.2021.100007.
- [46] S. Sahin and R. Tuna, ‘The effect of anxiety on thriving levels of university students during the COVID-19 pandemic’, *Collegian*, vol. 29, no. 3, pp. 263–270, Jun. 2022, doi: 10.1016/J.COLEGN.2021.10.004.
- [47] S. L. Beilock, E. A. Gunderson, G. Ramirez, and S. C. Levine, ‘Female teachers ’ math anxiety affects girls ’ math achievement’, vol. 2009, no. 1, 2009, doi: 10.1073/pnas.0910967107.
- [48] M. I. Pramanik, R. Y. K. Lau, H. Demirkan, and M. A. K. Azad, ‘Smart health: Big data enabled health paradigm within smart cities’, *Expert Systems with Applications*, vol. 87, pp. 370–383, 2017, doi: 10.1016/j.eswa.2017.06.027.
- [49] A. V. L. N. Sujith, G. S. Sajja, V. Mahalakshmi, S. Nuhmani, and B. Prasanalakshmi, ‘Systematic review of smart health monitoring using deep learning and Artificial intelligence’, *Neuroscience Informatics*, vol. 2, no. 3, p. 100028, 2022, doi: 10.1016/j.neuri.2021.100028.
- [50] L. S. Souza and M. S. Soares, ‘Combining SysML and Timed Coloured Petri Nets for Designing Smart City Applications’, *JUCS - Journal of Universal Computer Science*, vol. 29, no. 10, pp. 1217–1250, 2023, doi: 10.3897/jucs.97170.
- [51] H. Ziwei *et al.*, ‘The applications of internet of things in smart healthcare sectors: a bibliometric and deep study’, *Helijon*, vol. 10, no. 3, p. e25392, 2024, doi: <https://doi.org/10.1016/j.helijon.2024.e25392>.
- [52] A. Caragliu, C. Del Bo, and P. Nijkamp, ‘Smart cities in Europe’, 2009. [Onlajn]. Available: <https://air.unimi.it/handle/2434/72594>
- [53] X. Luo *et al.*, ‘Applying interpretable deep learning models to identify chronic cough patients using EHR data’, *Computer Methods and Programs in Biomedicine*, vol. 210, p. 106395, 2021, doi: 10.1016/j.cmpb.2021.106395.
- [54] S. Du, W. Liu, S. Cai, Y. Hu, and J. Dong, ‘The efficacy of e-health in the self-management of chronic low back pain: A meta analysis’, *International Journal of Nursing Studies*, vol. 106, p. 103507, 2020, doi: 10.1016/j.ijnurstu.2019.103507.
- [55] R. R. Pai *et al.*, ‘Bibliometric Analysis and Methodological Review of Mobile Health Services and Applications in India’, *Journal of Neonatal Nursing*, vol. 2, no. 6, pp. 41–47, 2021, doi: 10.1016/j.ijmedinf.2020.104330.
- [56] S. Khanjari, E. F. Bell, L. A. Sadeghi, M. kazem Sabzehei, and S. Haghani, ‘The impact of a mobile health intervention on the sense of coherence and quality of life of mothers with premature infants’, *Journal of Neonatal Nursing*, vol. 27, no. 6, pp. 444–450, 2021, doi: 10.1016/j.jnn.2021.06.008.

- [57] K. Fan and Y. Zhao, ‘Mobile health technology: a novel tool in chronic disease management’, *Intelligent Medicine*, vol. 2, no. 1, pp. 41–47, 2022, doi: 10.1016/j.imed.2021.06.003.
- [58] L. Lolich, I. Riccò, B. Deusdad, and V. Timonen, ‘Embracing technology? Health and Social Care professionals’ attitudes to the deployment of e-Health initiatives in elder care services in Catalonia and Ireland’, *Technological Forecasting and Social Change*, vol. 147, no. June, pp. 63–71, 2019, doi: 10.1016/j.techfore.2019.06.012.
- [59] N. K. Suryadevara and S. C. Mukhopadhyay, ‘Determining wellness through an ambient assisted living environment’, *IEEE Intelligent Systems*, vol. 29, no. 3, pp. 30–37, 2014, doi: 10.1109/MIS.2014.16.
- [60] S. Chaudhary *et al.*, ‘A taxonomy on smart healthcare technologies: Security framework, case study, and future directions’, *Journal of Sensors*, vol. 2022, no. 1, p. 1863838, 2022.
- [61] A. Raj, S. Prakash, and J. Srivastava, ‘Internet of Everything: A Review on Smart Healthcare Taxonomy, Research Challenges and Methodologies’, in *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 2023, pp. 1–6.
- [62] K. Liu and D. Tao, ‘The roles of trust, personalization, loss of privacy, and anthropomorphism in public acceptance of smart healthcare services’, *Computers in Human Behavior*, vol. 127, p. 107026, 2022.
- [63] P. Gope and T. Hwang, ‘BSN-Care: A secure IoT-based modern healthcare system using body sensor network’, *IEEE sensors journal*, vol. 16, no. 5, pp. 1368–1376, 2015.
- [64] M. Memedi, G. Tshering, M. Fogelberg, I. Jusufi, E. Kolkowska, and G. Klein, ‘An interface for IoT: feeding back health-related data to Parkinson’s disease patients’, *Journal of Sensor and Actuator Networks*, vol. 7, no. 1, p. 14, 2018.
- [65] A. E. Chung, R. E. Jensen, and E. M. Basch, ‘Leveraging emerging technologies and the “Internet of Things” to improve the quality of cancer care’, *Journal of oncology practice*, vol. 12, no. 10, p. 863, 2016.
- [66] T. N. Gia *et al.*, ‘IoT-based continuous glucose monitoring system: A feasibility study’, *Procedia Computer Science*, vol. 109, pp. 327–334, 2017.
- [67] V. Mishra and M. K. P. Naik, ‘Uses of wireless devices and IoT in management of diabetes’, in *Proceedings of national conference on emerging trends in science, technology & management*, 2017, pp. 14–21.
- [68] M. P. Savaridass, N. Ikram, R. Deepika, and R. Aarnika, ‘Development of smart health monitoring system using Internet of Things’, *Materials Today: Proceedings*, vol. 45, pp. 986–989, 2021.
- [69] S. M. Nagarajan, G. G. Deverajan, P. Chatterjee, W. Alnumay, and U. Ghosh, ‘Effective task scheduling algorithm with deep learning for Internet of Health Things (IoHT) in sustainable smart cities’, *Sustainable Cities and Society*, vol. 71, p. 102945, 2021.
- [70] I. Keshta, ‘AI-driven IoT for smart health care: Security and privacy issues’, *Informatics in medicine Unlocked*, vol. 30, p. 100903, 2022.
- [71] A. Khadivar, P. H. Ghale, and F. Lotfi, ‘A Model to Accepting the Internet of Things by Health Managers in Iran: A Mixed Approach’, *International Journal of Computer Information Systems and Industrial Management Applications*, vol. 16, no. 1, p. 16, 2024.
- [72] S. Choudhary *et al.*, ‘A Machine Learning Approach for Continuous Mining of Nonidentifiable Smartphone Data to Create a Novel Digital Biomarker Detecting Generalized Anxiety Disorder: Prospective Cohort Study’, *JMIR Medical Informatics*, vol. 10, no. 8, p. e38943, Aug. 2022, doi: 10.2196/38943.

- [73] K. Pullyblank, W. Brunner, M. Scribani, N. Krupa, M. G. Ory, and M. L. Smith, ‘Recruitment and engagement in disease self-management programs: Special concerns for rural residents reporting depression and/or anxiety’, *Preventive Medicine Reports*, vol. 26, p. 101761, Apr. 2022, doi: 10.1016/J.PMEDR.2022.101761.
- [74] W. A. Bokma *et al.*, ‘Predicting the naturalistic course in anxiety disorders using clinical and biological markers: A machine learning approach’, *Psychological Medicine*, 2020, doi: 10.1017/S0033291720001658.
- [75] A. K. Das, S. K. Biswas, A. Mandal, A. Bhattacharya, and S. Sanyal, ‘Machine Learning based Intelligent System for Breast Cancer Prediction (MLISBCP)’, *Expert Systems with Applications*, vol. 242, p. 122673, 2024, doi: <https://doi.org/10.1016/j.eswa.2023.122673>.
- [76] H. Wei and J. Sun, ‘Examining attentional control deficits in adolescents with test anxiety: An evidential synthesis using self-report, behavioral, and resting-state EEG measures’, *Acta Psychologica*, vol. 246, p. 104257, 2024.
- [77] D. Gruda and S. Hasan, ‘Feeling anxious? Perceiving anxiety in tweets using machine learning’, *Computers in Human Behavior*, vol. 98, pp. 245–255, Sep. 2019, doi: 10.1016/j.chb.2019.04.020.
- [78] W. Youyou, M. Kosinski, and D. Stillwell, ‘Computer-based personality judgments are more accurate than those made by humans’, *Proceedings of the National Academy of Sciences of the United States of America*, vol. 112, no. 4, pp. 1036–1040, 2015, doi: 10.1073/pnas.1418680112.
- [79] S. Aslam, ‘Twitter by the numbers: Stats, demographics & fun facts’, *Omnicoreagency.com*, 2018.
- [80] D. Lantos, D. Moreno-Agostino, L. T. Harris, G. Ploubidis, L. Haselden, and E. Fitzsimons, ‘The performance of long vs. short questionnaire-based measures of depression, anxiety, and psychological distress among UK adults: A comparison of the patient health questionnaires, generalized anxiety disorder scales, malaise inventory, and Kessler scale’, *Journal of Affective Disorders*, vol. 338, pp. 433–439, 2023.
- [81] R. Toscano, J. L. Hudson, A. J. Baillie, H. J. Lyneham, and L. F. McLellan, ‘Development of the Macquarie Anxiety Behavioural Scale (MABS): A parent measure to assess anxiety in children and adolescents including young people with autism spectrum disorder’, *Journal of Affective Disorders*, vol. 276, pp. 678–685, 2020.
- [82] H. Hermens, H. op den Akker, M. Tabak, J. Wijsman, and M. Vollenbroek, ‘Personalized Coaching Systems to support healthy behavior in people with chronic conditions’, *Journal of Electromyography and Kinesiology*, vol. 24, no. 6. Elsevier Ltd, pp. 815–826, Dec. 01, 2014. doi: 10.1016/j.jelekin.2014.10.003.
- [83] M. Pritchard, K. Brasil, R. McDermott, and A. Holdiman, ‘Untangling the associations between generalized anxiety and body dissatisfaction: The mediating effects of social physique anxiety among collegiate men and women’, *Body Image*, vol. 39, pp. 266–275, 2021, doi: 10.1016/j.bodyim.2021.10.002.
- [84] A. Conde, R. Costa, and B. Figueiredo, ‘Anxiety and depressive symptoms effects on cortisol trajectories from pregnancy to postpartum: Differences and similarities between women and men’, *Hormones and Behavior*, vol. 128, no. January 2020, 2021, doi: 10.1016/j.yhbeh.2020.104917.
- [85] S. Varshney, J. Varshney, U. Varshney, and S. Varshney, ‘AlzhaTV: A Smart Phone App for Managing Depression, Anxiety, and Agitation in Nursing Home Dementia Patients’, *The American Journal of Geriatric Psychiatry*, vol. 24, no. 3, pp. S148–S149, Mar. 2016, doi: 10.1016/J.JAGP.2016.02.020.

- [86] N. C. Jacobson and S. Bhattacharya, ‘Digital biomarkers of anxiety disorder symptom changes: Personalized deep learning models using smartphone sensors accurately predict anxiety symptoms from ecological momentary assessments’, *Behaviour Research and Therapy*, vol. 149, p. 104013, Feb. 2022, doi: 10.1016/J.BRAT.2021.104013.
- [87] G. Ran, J. Li, Q. Zhang, and X. Niu, ‘The association between social anxiety and mobile phone addiction: A three-level meta-analysis’, *Computers in Human Behavior*, vol. 130, p. 107198, May 2022, doi: 10.1016/J.CHB.2022.107198.
- [88] K. N. Koly *et al.*, ‘Exploring the potential of delivering mental health care services using digital technologies in Bangladesh: A qualitative analysis’, *Internet Interventions*, vol. 29, Sep. 2022, doi: 10.1016/J.INVENT.2022.100544.
- [89] F. Rencz and M. F. Janssen, ‘Analyzing the Pain/Discomfort and Anxiety/Depression Composite Domains and the Meaning of Discomfort in the EQ-5D: A Mixed-Methods Study’, *Value in Health*, 2022, doi: 10.1016/J.JVAL.2022.06.012.
- [90] D. Adikoeswanto, A. Eliyana, N. Syamsudin, S. Budiyanto, Z. Arief, and A. Anwar, ‘The mediation role of adoption readiness on perceived anxiety and attitude toward using database management system at correctional institutions’, *Helijon*, vol. 8, no. 8, p. e10027, Aug. 2022, doi: 10.1016/J.HELIYON.2022.E10027.
- [91] S. R. Alcorn and M. J. Cheesman, ‘Technology-assisted viva voce exams: A novel approach aimed at addressing student anxiety and assessor burden in oral assessment’, *Currents in Pharmacy Teaching and Learning*, vol. 14, no. 5, pp. 664–670, May 2022, doi: 10.1016/J.CPTL.2022.04.009.
- [92] F. Lotfi, K. Fatehi, and N. Badie, ‘An Analysis of Key Factors to Mobile Health Adoption using Fuzzy AHP’, *International Journal of Information Technology and Computer Science*, vol. 12, no. 2, pp. 1–17, 2020, doi: 10.5815/ijitcs.2020.02.01.
- [93] M. J. Rahman, B. I. Morshed, B. Harmon, and M. Rahman, ‘A pilot study towards a smart-health framework to collect and analyze biomarkers with low-cost and flexible wearables’, *Smart Health*, vol. 23, p. 100249, 2022.
- [94] S. Huang, J. Li, P. Zhang, and W. Zhang, ‘Detection of mental fatigue state with wearable ECG devices’, *International journal of medical informatics*, vol. 119, pp. 39–46, 2018.
- [95] H. Hunkin, D. L. King, and I. T. Zajac, ‘Wearable devices as adjuncts in the treatment of anxiety-related symptoms: A narrative review of five device modalities and implications for clinical practice’, *Clinical Psychology: Science and Practice*, vol. 26, no. 3, p. e12290, 2019.
- [96] G. Pramana, B. Parmanto, P. C. Kendall, and J. S. Silk, ‘The SmartCAT: An m-health platform for ecological momentary intervention in child anxiety treatment’, *Telemedicine and e-Health*, vol. 20, no. 5, pp. 419–427, 2014, doi: 10.1089/tmj.2013.0214.
- [97] L. Leung and C. Chen, ‘E-health/m-health adoption and lifestyle improvements: Exploring the roles of technology readiness, the expectation-confirmation model, and health-related information activities’, *Telecommunications Policy*, vol. 43, no. 6, pp. 563–575, 2019, doi: 10.1016/j.telpol.2019.01.005.
- [98] J. R. D. McIntosh, S. Jay, N. Hadden, and P. J. Whittaker, ‘Do E-health interventions improve physical activity in young people: a systematic review’, *Public Health*, vol. 148, pp. 140–148, 2017, doi: 10.1016/j.puhe.2017.04.001.
- [99] N. C. Jacobson *et al.*, ‘M-SEQ: Early detection of anxiety and depression via temporal orders of diagnoses in electronic health data’, *Proceedings - 2015 IEEE International Conference on Big Data, IEEE Big Data 2015*, vol. 148, no. October, pp. 140–148, Mar. 2015, doi: 10.1016/j.puhe.2017.04.001.

- [100] S. Hwang and J. Y. Nam, ‘Do lifestyle risk behaviors affect anxiety, depressive symptoms, and suicidal ideation among adolescents?’, *Psychiatry Research*, vol. 318, p. 114942, Dec. 2022, doi: 10.1016/J.PSYCHRES.2022.114942.
- [101] H. Onyeaka *et al.*, ‘Use of wearable devices among individuals with depression and anxiety: a population level study’, *Psychiatry Research Communications*, vol. 2, no. 4, p. 100081, 2022.
- [102] A. Ahmed *et al.*, ‘Wearable devices for anxiety & depression: a scoping review’, *Computer Methods and Programs in Biomedicine Update*, vol. 3, p. 100095, 2023.
- [103] J. Tomasi *et al.*, ‘Investigating the association of anxiety disorders with heart rate variability measured using a wearable device’, *Journal of Affective Disorders*, vol. 351, pp. 569–578, 2024.
- [104] E. P. Balogh, B. T. Miller, and J. R. Ball, *Improving diagnosis in health care*. Washington (DC): National Academies Press (US), 2015. [Onlajn]. Available: <https://pubmed.ncbi.nlm.nih.gov/26803862/>
- [105] N. C. Jacobson, D. Lekkas, R. Huang, and N. Thomas, ‘Deep learning paired with wearable passive sensing data predicts deterioration in anxiety disorder symptoms across 17–18 years’, *Journal of Affective Disorders*, vol. 282, pp. 104–111, Mar. 2021, doi: 10.1016/j.jad.2020.12.086.
- [106] L. M. Shin, F. Davis, M. B. VanElzakker, M. K. Dahlgren, and S. J. Dubois, ‘Neuroimaging predictors of treatment response in anxiety disorders’, *Biology of Mood & Anxiety Disorders*, vol. 3, no. 1, p. 15, 2013, doi: 10.1186/2045-5380-3-15.
- [107] A. Daza, N. Saboya, J. I. Necochea-Chamorro, K. Zavaleta Ramos, and Y. del R. Vásquez Valencia, ‘Systematic review of machine learning techniques to predict anxiety and stress in college students’, *Informatics in Medicine Unlocked*, vol. 43, p. 101391, 2023, doi: <https://doi.org/10.1016/j imu.2023.101391>.
- [108] M. Ciharova *et al.*, ‘Use of Machine-Learning Algorithms Based on Text, Audio and Video Data in the Prediction of Anxiety and Post-Traumatic Stress in General and Clinical Populations: A Systematic Review’, *Biological psychiatry*, 2024.
- [109] J. Abbas *et al.*, ‘The moderating role of social support for marital adjustment, depression, anxiety, and stress: Evidence from Pakistani working and nonworking women’, *Journal of Affective Disorders*, vol. 244, pp. 231–238, 2019, doi: 10.1016/j.jad.2018.07.071.
- [110] W. L. Sergio, V. Ströele, M. Dantas, R. Braga, and D. D. Macedo, ‘Enhancing well-being in modern education: A comprehensive eHealth proposal for managing stress and anxiety based on machine learning’, *Internet of Things*, vol. 25, p. 101055, 2024.
- [111] A. Sau and I. Bhakta, ‘Screening of anxiety and depression among the seafarers using machine learning technology’, *Informatics in Medicine Unlocked*, vol. 16, Jan. 2019, doi: 10.1016/j imu.2018.12.004.
- [112] M. M. Islam, S. Hassan, S. Akter, F. A. Jibon, and M. Sahidullah, ‘A comprehensive review of predictive analytics models for mental illness using machine learning algorithms’, *Healthcare Analytics*, p. 100350, 2024.
- [113] S. Bhatnagar, J. Agarwal, and O. R. Sharma, ‘Detection and classification of anxiety in university students through the application of machine learning’, *Procedia Computer Science*, vol. 218, pp. 1542–1550, 2023, doi: <https://doi.org/10.1016/j.procs.2023.01.132>.
- [114] S. S. Malik and A. Khan, ‘Anxiety, Depression and Stress prediction among College Students using Machine Learning Algorithms’, in *2023 Second International Conference on Electrical, Electronics, Information and Communication Technologies (ICEEICT)*, 2023, pp. 1–5. doi: 10.1109/ICEEICT56924.2023.10157693.

- [115] S. V. Praveen, R. Ittamalla, and G. Deepak, ‘Analyzing Indian general public’s perspective on anxiety, stress and trauma during Covid-19 - A machine learning study of 840,000 tweets’, *Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, vol. 15, no. 3, pp. 667–671, May 2021, doi: 10.1016/J.DSX.2021.03.016.
- [116] F. M. Albagmi, A. Alansari, D. S. Al Shawan, H. Y. AlNujaidi, and S. O. Olatunji, ‘Prediction of generalized anxiety levels during the Covid-19 pandemic: A machine learning-based modeling approach’, *Informatics in Medicine Unlocked*, vol. 28, Jan. 2022, doi: 10.1016/J.IMU.2022.100854.
- [117] K. Liu, B. Droncheff, and S. L. Warren, ‘Predictive utility of symptom measures in classifying anxiety and depression: A machine-learning approach’, *Psychiatry Research*, vol. 312, p. 114534, Jun. 2022, doi: 10.1016/J.PSYCHRES.2022.114534.
- [118] A. Ahmed *et al.*, ‘Machine learning models to detect anxiety and depression through social media: A scoping review’, *Computer Methods and Programs in Biomedicine Update*, vol. 2, p. 100066, 2022, doi: 10.1016/J.CMPBUP.2022.100066.
- [119] D. Gruda and A. Ojo, ‘All about that trait: Examining extraversion and state anxiety during the SARS-CoV-2 pandemic using a machine learning approach’, *Personality and Individual Differences*, vol. 188, Apr. 2022, doi: 10.1016/J.PAID.2021.111461.
- [120] N. C. Sattaru, M. R. Baker, D. Umrao, U. K. Pandey, M. Tiwari, and M. K. Chakravarthi, ‘Heart Attack Anxiety Disorder using Machine Learning and Artificial Neural Networks (ANN) Approaches’, *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering, ICACITE 2022*, pp. 680–683, 2022, doi: 10.1109/ICACITE53722.2022.9823697.
- [121] B. N. Teelhawod *et al.*, ‘Machine Learning in E-health: A Comprehensive Survey of Anxiety’, *2021 International Conference on Data Analytics for Business and Industry, ICDABI 2021*, pp. 167–172, 2021, doi: 10.1109/ICDABI53623.2021.9655966.
- [122] C. Wanderley Espinola, J. C. Gomes, J. Mônica Silva Pereira, and W. P. dos Santos, ‘Detection of major depressive disorder, bipolar disorder, schizophrenia and generalized anxiety disorder using vocal acoustic analysis and machine learning: an exploratory study’, *Research on Biomedical Engineering 2022 38:3*, vol. 38, no. 3, pp. 813–829, Jun. 2022, doi: 10.1007/S42600-022-00222-2.
- [123] Y. Garcia-Chimeno, B. Garcia-Zapirain, M. Gomez-Beldarrain, B. Fernandez-Ruanova, and J. C. Garcia-Monco, ‘Automatic migraine classification via feature selection committee and machine learning techniques over imaging and questionnaire data’, *BMC Medical Informatics and Decision Making*, vol. 17, no. 1, Apr. 2017, doi: 10.1186/s12911-017-0434-4.
- [124] W. A. van Eeden *et al.*, ‘Predicting the 9-year course of mood and anxiety disorders with automated machine learning: A comparison between auto-sklearn, naïve Bayes classifier, and traditional logistic regression’, *Psychiatry Research*, vol. 299, May 2021, doi: 10.1016/J.PSYCHRES.2021.113823.
- [125] A. Sharma and W. J. M. I. Verbeke, ‘Understanding importance of clinical biomarkers for diagnosis of anxiety disorders using machine learning models’, *PLoS ONE*, vol. 16, no. 5 May 2021, pp. 1–16, 2021, doi: 10.1371/journal.pone.0251365.
- [126] G. Demiris *et al.*, ‘Spoken words as biomarkers: Using machine learning to gain insight into communication as a predictor of anxiety’, *Journal of the American Medical Informatics Association*, vol. 27, no. 6, pp. 929–933, 2020, doi: 10.1093/jamia/ocaa049.
- [127] R. S. McGinnis *et al.*, ‘Rapid detection of internalizing diagnosis in young children enabled by wearable sensors and machine learning’, *PLoS ONE*, vol. 14, no. 1, pp. 1–16, 2019, doi: 10.1371/journal.pone.0210267.

- [128] F. R. Ihmig, H. Antonio Gogeaescochea, F. Neurohr-Parakenings, S. K. Schäfer, J. Lass-Hennemann, and T. Michael, ‘On-line anxiety level detection from biosignals: Machine learning based on a randomized controlled trial with spider-fearful individuals’, *PLoS ONE*, vol. 15, no. 6, pp. 1–20, 2020, doi: 10.1371/journal.pone.0231517.
- [129] R. S. McGinnis *et al.*, ‘Wearable sensors and machine learning diagnose anxiety and depression in young children’, *2018 IEEE EMBS International Conference on Biomedical and Health Informatics, BHI 2018*, vol. 2018-Janua, no. March, pp. 410–413, 2018, doi: 10.1109/BHI.2018.8333455.
- [130] A. J. Masino *et al.*, ‘M-Health and autism: Recognizing stress and anxiety with machine learning and wearables data’, in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, Jun. 2019, vol. 2019-June, pp. 714–719. doi: 10.1109/CBMS.2019.00144.
- [131] M. D. Nemesure, M. V. Heinz, R. Huang, and N. C. Jacobson, ‘Predictive modeling of depression and anxiety using electronic health records and a novel machine learning approach with artificial intelligence’, *Scientific Reports*, vol. 11, no. 1, Dec. 2021, doi: 10.1038/s41598-021-81368-4.
- [132] G. Schiavo, S. Businaro, and M. Zancanaro, ‘Comprehension, apprehension, and acceptance: Understanding the influence of literacy and anxiety on acceptance of artificial Intelligence’, *Technology in Society*, vol. 77, p. 102537, 2024.
- [133] M. J. Duncan, N. A. Riazi, G. Faulkner, J. D. Gilchrist, S. T. Leatherdale, and K. A. Patte, ‘The association of physical activity, sleep, and screen time with mental health in Canadian adolescents during the COVID-19 pandemic: A longitudinal isotemporal substitution analysis’, *Mental Health and Physical Activity*, vol. 23, p. 100473, Oct. 2022, doi: 10.1016/J.MHPA.2022.100473.
- [134] J. D. Omura, D. R. Brown, L. C. McGuire, C. A. Taylor, J. E. Fulton, and S. A. Carlson, ‘Cross-sectional association between physical activity level and subjective cognitive decline among US adults aged  $\geq 45$  years, 2015’, *Preventive Medicine*, vol. 141, p. 106279, Dec. 2020, doi: 10.1016/J.YPMED.2020.106279.
- [135] S. Rana, V. Soni, A. K. Bairwa, and S. Joshi, ‘A Review for Prediction of Anxiety Disorders in Humans Using Machine Learning’, *2021 IEEE Bombay Section Signature Conference, IBSSC 2021*, 2021, doi: 10.1109/IBSSC53889.2021.9673471.
- [136] M. Olfson, C. Blanco, S. Wang, G. Laje, and C. U. Correll, ‘National Trends in the Mental Health Care of Children, Adolescents, and Adults by Office-Based Physicians’, *JAMA Psychiatry*, vol. 71, no. 1, pp. 81–90, Jan. 2014, doi: 10.1001/JAMAPSYCHIATRY.2013.3074.
- [137] A. Oduntan, O. Oyebode, A. H. Beltran, J. Fowles, D. Steeves, and R. Orji, ““I Let Depression and Anxiety Drown Me...”: Identifying Factors Associated With Resilience Based on Journaling Using Machine Learning and Thematic Analysis”, *IEEE Journal of Biomedical and Health Informatics*, vol. 26, no. 7, pp. 3397–3408, Jul. 2022, doi: 10.1109/JBHI.2022.3149862.
- [138] C. El Morr *et al.*, ‘Predictive Machine Learning Models for Assessing Lebanese University Students’ Depression, Anxiety, and Stress During COVID-19’, *Journal of Primary Care & Community Health*, vol. 15, p. 21501319241235588, 2024.
- [139] Y. Jia and E. Wang, ‘Research on Information Anxiety of College Students under the Background of Information Overloaded Based on Support Vector Machine Optimization Algorithm’, *Proceedings - 2021 2nd International Conference on Information Science and Education, ICISE-IE 2021*, pp. 484–487, 2021, doi: 10.1109/ICISE-IE53922.2021.00117.
- [140] L. C. L. Portugal *et al.*, ‘Predicting anxiety from wholebrain activity patterns to emotional faces in young adults: a machine learning approach’, *NeuroImage: Clinical*, vol. 23, Jan. 2019,

doi: 10.1016/J.NICL.2019.101813.

- [141] Z. Huang *et al.*, ‘Nomogram reliability for predicting potential risk in postgraduate medical students with anxiety symptoms’, *Heliyon*, vol. 8, no. 10, p. e10803, Oct. 2022, doi: 10.1016/J.HELION.2022.E10803.
- [142] B.-H. Kim, M.-K. Kim, H.-J. Jo, and J.-J. Kim, ‘Predicting social anxiety in young adults with machine learning of resting-state brain functional radiomic features’, *Scientific Reports*, vol. 12, p. 13932, 123AD, doi: 10.1038/s41598-022-17769-w.
- [143] I. J. Ratul, M. M. Nishat, F. Faisal, S. Sultana, A. Ahmed, and M. A. Al Mamun, ‘Analyzing Perceived Psychological and Social Stress of University Students: A Machine Learning Approach’, *Heliyon*, vol. 9, no. 6, p. e17307, 2023, doi: <https://doi.org/10.1016/j.heliyon.2023.e17307>.
- [144] A. Daza, Arroyo-Paz, J. Bobadilla, O. Apaza, and J. Pinto, ‘Stacking ensemble learning model for predict anxiety level in university students using balancing methods’, *Informatics in Medicine Unlocked*, vol. 42, p. 101340, 2023, doi: <https://doi.org/10.1016/j.imu.2023.101340>.
- [145] A. Singh and D. Kumar, ‘Computer assisted identification of stress, anxiety, depression (SAD) in students: A state-of-the-art review’, *Medical Engineering & Physics*, vol. 110, p. 103900, 2022, doi: <https://doi.org/10.1016/j.medengphy.2022.103900>.
- [146] S. Mittal, S. Mahendra, V. Sanap, and P. Churi, ‘How can machine learning be used in stress management: A systematic literature review of applications in workplaces and education’, *International Journal of Information Management Data Insights*, vol. 2, no. 2, p. 100110, 2022, doi: <https://doi.org/10.1016/j.jjimei.2022.100110>.
- [147] V. Hamilton, Y. Onder, N. R. Andzik, and T. D. Reeves, ‘Do Data-Driven Decision-Making Efficacy and Anxiety Inventory Scores Mean the Same Thing for Pre-Service and In-Service Teachers?’, *Journal of Psychoeducational Assessment*, vol. 40, no. 4, pp. 482–498, Jan. 2022, doi: 10.1177/07342829211069220.
- [148] E. A. Boeke, A. J. Holmes, and E. A. Phelps, ‘Toward Robust Anxiety Biomarkers: A Machine Learning Approach in a Large-Scale Sample’, *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, vol. 5, no. 8, pp. 799–807, Aug. 2020, doi: 10.1016/J.BPSC.2019.05.018.
- [149] A. Wenzel, ‘State-Trait Anxiety Inventory’, *The SAGE Encyclopedia of Abnormal and Clinical Psychology*, pp. 3–4, 2017, doi: 10.4135/9781483365817.n1316.
- [150] C. D. Spielberger, R. L. Gorsuch, R. Lushene, P. R. Vagg, and G. A. Jacobs, ‘State-Trait Anxiety Inventory for Adults (Form Y): Manual, Test, Scoring Key. Redwood City’, CA: Mind Garden Inc, 1983.
- [151] F. Lotfi and B. Rodić, ‘A System to Monitoring and Managing the Anxiety Among the Young People Using Machine Learning’, pp. 91–94, 2022.
- [152] D. Bordoloi, V. Singh, S. Sanober, S. M. Buhari, J. A. Ujjan, and R. Boddu, ‘Deep Learning in Healthcare System for Quality of Service’, 2022, doi: 10.1155/2022/8169203.
- [153] D. Yang, ‘Correlogram, predictability error growth, and bounds of mean square error of solar irradiance forecasts’, *Renewable and Sustainable Energy Reviews*, vol. 167, no. April, p. 112736, 2022, doi: 10.1016/j.rser.2022.112736.
- [154] F. Centofanti, M. Fontana, A. Lepore, and S. Vantini, ‘Smooth LASSO estimator for the Function-on-Function linear regression model’, *Computational Statistics and Data Analysis*, vol. 176, 2022, doi: 10.1016/j.csda.2022.107556.
- [155] C. D. Spielberger, L. R. Gorsuch, R. Lushene, P. R. Vagg, and G. A. Jacobs, ‘Consulting Psychologists Press; Palo Alto, CA: 1983.’, 1983.

- [156] C. D. Spielberger, ‘State-Trait Anxiety Inventory: Bibliography . Palo Alto, CA: Consulting PsychologistsPress’. 1989.
- [157] L. Tze Ping, K. Subramaniam, and S. Krishnaswamy, ‘Test anxiety: state, trait and relationship with exam satisfaction’, vol. 15, no. 2, pp. 18–23, 2008.
- [158] H. C. W. de Vet, L. B. Mokkink, D. G. Mosmuller, and C. B. Terwee, ‘Spearman–Brown prophecy formula and Cronbach’s alpha: different faces of reliability and opportunities for new applications’, *Journal of Clinical Epidemiology*, vol. 85, pp. 45–49, May 2017, doi: 10.1016/J.JCLINEPI.2017.01.013.
- [159] F. Martin, Y. Chen, R. L. Moore, and C. D. Westine, ‘Systematic review of adaptive learning research designs, context, strategies, and technologies from 2009 to 2018’, *Educational Technology Research and Development*, vol. 68, no. 4, pp. 1903–1929, 2020, doi: 10.1007/s11423-020-09793-2.
- [160] I. Ilic, B. Görgülü, M. Cevik, and M. G. Baydoğan, ‘Explainable boosted linear regression for time series forecasting’, *Pattern Recognition*, vol. 120, p. 108144, Dec. 2021, doi: 10.1016/J.PATCOG.2021.108144.
- [161] Q. H. Luu, M. F. Lau, S. P. H. Ng, and T. Y. Chen, ‘Testing multiple linear regression systems with metamorphic testing’, *Journal of Systems and Software*, vol. 182, p. 111062, Dec. 2021, doi: 10.1016/J.JSS.2021.111062.
- [162] H. Tunc and B. Genç, ‘A column generation based heuristic algorithm for piecewise linear regression’, *Expert Systems with Applications*, vol. 171, p. 114539, Jun. 2021, doi: 10.1016/J.ESWA.2020.114539.
- [163] D. S. K. Karunasingha, ‘Root mean square error or mean absolute error? Use their ratio as well’, *Information Sciences*, vol. 585, pp. 609–629, Mar. 2022, doi: 10.1016/J.INS.2021.11.036.
- [164] M. Emami, M. Sahraee-Ardakan, P. Pandit, S. Rangan, and A. Fletcher, ‘Generalization error of generalized linear models in high dimensions’, in *International Conference on Machine Learning*, 2020, pp. 2892–2901.
- [165] R. K. Nath and H. Thapliyal, ‘Machine Learning-Based Anxiety Detection in Older Adults Using Wristband Sensors and Context Feature’, *SN Computer Science* 2021 2:5, vol. 2, no. 5, pp. 1–12, Jun. 2021, doi: 10.1007/S42979-021-00744-Z.
- [166] A. El-Ansary, ‘Data of multiple regressions analysis between selected biomarkers related to glutamate excitotoxicity and oxidative stress in Saudi autistic patients’, *Data in Brief*, vol. 7, pp. 111–116, Jun. 2016, doi: 10.1016/J.DIB.2016.02.025.
- [167] V. Chang, V. R. Bhavani, A. Q. Xu, and M. Hossain, ‘An artificial intelligence model for heart disease detection using machine learning algorithms’, *Healthcare Analytics*, vol. 2, p. 100016, Nov. 2022, doi: 10.1016/J.HEALTH.2022.100016.
- [168] M. Barchitta *et al.*, ‘Cluster analysis identifies patients at risk of catheter-associated urinary tract infections in intensive care units: findings from the SPIN-UTI Network’, *Journal of Hospital Infection*, vol. 107, pp. 57–63, 2021, doi: 10.1016/j.jhin.2020.09.030.
- [169] T. Salazar-Rojas, F. R. Cejudo-Ruiz, and G. Calvo-Brenes, ‘Comparison between machine linear regression (MLR) and support vector machine (SVM) as model generators for heavy metal assessment captured in biomonitoring and road dust’, *Environmental Pollution*, vol. 314, p. 120227, Dec. 2022, doi: 10.1016/J.ENVPOL.2022.120227.
- [170] A. M. Ikotun, A. E. Ezugwu, L. Abualigah, B. Abuhaija, and J. Heming, ‘K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data’, *Information Sciences*, vol. 622, pp. 178–210, Apr. 2023, doi: 10.1016/J.INS.2022.11.139.

- [171] A. Metin, E. S. Erbiçer, S. Şen, and A. Çetinkaya, ‘Gender and COVID-19 related fear and anxiety: A meta-analysis’, *Journal of Affective Disorders*, vol. 310, pp. 384–395, Aug. 2022, doi: 10.1016/J.JAD.2022.05.036.
- [172] M. F. Tsai, P. Chen, and Y. J. Hong, ‘Enhancing the utilization of public bike sharing systems using return anxiety information’, *Future Generation Computer Systems*, vol. 92, pp. 961–971, Mar. 2019, doi: 10.1016/J.FUTURE.2017.12.063.
- [173] M. S. Wiglusz, J. Landowski, and W. J. Cubała, ‘Psychometric properties and diagnostic utility of the State–Trait Anxiety Inventory in epilepsy with and without comorbid anxiety disorder’, *Epilepsy & Behavior*, vol. 92, pp. 221–225, Mar. 2019, doi: 10.1016/J.YEBEH.2019.01.005.
- [174] T. Richter, B. Fishbain, A. Markus, G. Richter-Levin, and H. Okon-Singer, ‘Using machine learning-based analysis for behavioral differentiation between anxiety and depression’, *Scientific Reports*, vol. 10, no. 1, pp. 1–12, Dec. 2020, doi: 10.1038/s41598-020-72289-9.
- [175] C. Hernández-Martínez, V. Arija, J. Escribano, and J. Canals, ‘Does maternal anxiety affect neonatal behaviour differently in boys and girls?’, *Early Human Development*, vol. 86, no. 4, pp. 209–211, Apr. 2010, doi: 10.1016/J.EARLHUMDEV.2010.03.001.
- [176] L. A. Serbin, K. D. O’Leary, R. N. Kent, and I. J. Tonick, ‘A Comparison of Teacher Response to the Preacademic and Problem Behavior of Boys and Girls’, *Child Development*, vol. 44, no. 4, pp. 796–804, Feb. 1973, doi: 10.2307/1127726.
- [177] Lotfi, F., B. Rodić, A. Labus, and Z. Bogdanović, ‘Smart healthcare: developing a pattern to predict the stress and anxiety among university students using machine learning technology’, *Journal of Universal Computer Science*, vol. 30, no. 10 (2024), 1316-1342. DOI:10.3897/jucs.116174.

## **Lista tabela**

Tabela 1. Demografski podaci i dijagnoze [81] .....	18
Tabela 2. Istraživanja u oblasti predviđanja anksioznosti putem mašinskog učenja. ....	32
Tabela 3. Pregled istraživanja o otkrivanju anksioznosti mlađih ili studenata korišćenjem mašinskog učenja. ....	34
Tabela 4. Demografski profil ispitanika.....	44
Tabela 5. Opis učesnika korišćen u istraživanju. ....	45
Tabela 6. Cronbach-ova Alfa skupa podataka o anksioznosti. ....	46
Tabela 7. Rezultati dobijeni analizom STAI upitnika.....	54
Tabela 8. Više informacija o studentima.....	55
Tabela 9. Pogodna pitanja u vezi sa interesovanjem za korišćenje pametne zdravstvene zaštite među univerzitetskim studentima.....	56
Tabela 10. Pušenje i fizičke aktivnosti kod učenika. ....	56
Tabela 11. Metrika greške / tačnosti anksioznosti stanja i anksioznosti osobina u linearnoj regresiji pomoću MAE i MSE.....	58
Tabela 12. Rezultati i rezultati anksioznosti stanja. ....	61
Tabela 13. Pušenje cigareta, fizičke aktivnosti i izveštaji o prosečnoj oceni tokom studiranja kod studentkinja. ....	62
Tabela 14. Rizične funkcije između faze pre i faze nakon intervencije.....	63
Tabela 15. Karakteristike klastera anksioznosti stanja u postintervencijskoj fazi. ....	65

## **Lista slika**

Slika 1. Taksonomija nekih komponenti pametne zdravstvene zaštite zajedno sa studijom slučaja, sigurnošću okvira i budućih pravaca pristupa [60]. .....	13
Slika 2. Internet svega (IoE) zasnovan na taksonomiji pametne zdravstvene zaštite [61].....	13
Slika 3. Model prihvatanja interneta inteligentnih uređaja od strane zdravstvenih menadžera [71]. .....	15
Slika 4. Korelacija među komponentama prikazana je raspršenom grafikom. ....	17
Slika 5. Neke ključne primene pametnog zdravstva [49].....	21
Slika 6. Dijagram toka analize literature za primenu nosivih uređaja kod anksioznosti i depresije [102].....	23
Slika 7. Komponente sistematskog pregleda literature o predviđanju anksioznosti na osnovu zvuka, teksta i videa pomoću tehnologije mašinskog učenja među kliničkom i opštom populacijom [108]. .....	26
Slika 8. Dijagram toka podataka o poboljšanju zdravlja u savremenom obrazovanju sa predlogom servisa e-zdravstva za upravljanje stresom i anksioznošću na osnovu mašinskog učenja [110].....	28
Slika 9. Klasifikacija i primenjena polja modela mašinskog učenja [112]. .....	30
Slika 10. Glavni predloženi model zasnovan je na pametnom zdravstvenom ekosistemu za otkrivanje i predviđanje stresa studenata koristeći AI u visokom obrazovanju.....	40
Slika 11. Istraživački pristup predviđanju anksioznosti učenika koristeći mašinsko učenje (anksioznost stanja i osobina među svim skupovima podataka učenika). .....	42
Slika 12. Blok dijagram, detekcija stresa i anksioznosti studentkinja .....	43
Slika 13. Test srednja kvadratna greška pod nelinearnom procenom najmanjeg kvadrata [164]. .....	50
Slika 14. K-means komponente algoritma za grupisanje. ....	52
Slika 15. Distribucija uzoraka za anksioznost stanja i anksioznost osobina. ....	57
Slika 16. Odnos anksioznosti satanja i anksioznosti osobina u skupu podataka.....	57
Slika 17. Raspodela razlika u izmerenim rosečnim vrednostima između stanja anksioznosti i osobine anksioznosti u celokupnom skupu podataka.....	58
Slika 18. Opcija sa najvećim uticajem nakon treninga skupa podataka anksioznosti stanja. .	59
Slika 19. Opcija sa najvećim uticajem nakon treninga podataka o anksioznosti osobina. ....	59
Slika 20. Provera preprilagođenosti i nedovoljne prilagođenosti stanja anksioznosti primenom algoritma K-najbližih suseda.....	60
Slika 21. Provera preprilagođenosti i nedovoljne prilagođenosti anksioznosti osobine primenom algoritma K-najbližih suseda. ....	61
Slika 22. Korelaciona matrična topplotna mapa generisana iz skupa podataka o stanju anksioznosti.....	63
Slika 23. Predviđanje linearног regresionог modela za stanje anksioznosti postintervencijske faze. .....	64

## Biografija

Farhad Lotfi rođen je 13. maja 1990. godine u Teheranu, glavnom gradu Irana. Završio je srednju školu za računarsko programiranje u gradu Khorramdarreh. Diplomirao je na Islamskom Azad univerzitetu, Abhar kampusu, sa zvanjem diplomiranog inženjera računarskih nauka. Zatim je zaposlen u istraživačkom centru City Bank (Shahr Bank) kao istraživač. Sa kolegama u istraživačkom centru, dizajnirao je i radio na održavanju naučnog portala, koristeći Share Point. Njegova istraživanja u istraživačkom centru City Banka bila su vezana za koncepte pametnih gradova poput pametnog transporta. U međuvremenu, zaposlen je u Iran Urban Economics Scientific Association u Teheranu kao IT stručnjak. Dizajnirao je i upravljao sa više veb stranica, uključujući i veb stranicu Journal of Urban Economics and Management. Završio je master studije na Islamskom Azad univerzitetu, South Tehran Branch, na programu Informacionih tehnologija - Elektronske trgovine, sa visokom ocenom 4,00 od 4,00. Odbranio je master tezu pod nazivom "Model za stabilizaciju e-lojalnosti prema uslugama zdravstva u kontekstu interneta stvari korišćenjem metode fuzzy AHP", pod mentorstvom dr. Soleimani, i objavio članak na jednoj IEEE konferenciji 2020. godine. Upisao je doktorske studije na Fakultetu organizacionih nauka, Univerziteta u Beogradu, na studijskom programu Informacioni sistemi i kvantitativni menadžment, studijska grupa Elektronsko poslovanje 2021. godine.

Godine 2023. pozvan je kao gostujući doktorski istraživač na Bečkom tehnološkom univerzitetu (TU Vien) na period od pet meseci. Tokom svog boravka na TU Vien, pohađao je dva seminara i učestvovao u časovima simulacije i vizuelizacije zasnovane na agensima, kao i naprednih tehnologija zdravstvene zaštite. Pored toga, razvio je svoju doktorsku tezu u bliskoj saradnji sa Odsekom za arhitekturu i digitalno planiranje na TU Vien.

Konačno, Farhad je imenovan za višeg istraživača na Medicinskom univerzitetu u Beču (MedUni Vien) od jula 2024. do decembra 2024. godine, sa pozicijom na pola radnog vremena. Radio je kao viši naučnik u Centru za nauku o medicinskim podacima i radio je kao naučnik podataka na projektu Smart FOKS. On i njegove kolege su bili uključeni u razvoj projekta pametne zdravstvene zaštite. Saradivali su i sa Austrijskim institutom za tehnologiju, Siemensom i drugim srodnim institucijama.

Anađovan je kao recenzent za sledeće časopise i konferencije:

- 2022 IEEE International Conference on Prognostics and Health Management (ICPHM)), IEEE Catalog Number: CFP22PHM-ART, Detroit (Romulus), Michigan, SAD.
- Journal of Intelligent & Fuzzy Systems, od 2021. godine, IF: 1.73
- Journal of Transactions on Internet and Information Systems, indeksiran u SCIE (Clarivate Analytics) i Scopusu, maj 2020. - decembar 2020. godine.

## Spisak publikacija [Časopisi i konferencije]

1. **Lotfi, F.**, B. Rodić, A. Labus, and Z. Bogdanović, ‘Smart healthcare: developing a pattern to predict the stress and anxiety among university students using machine learning technology’, Journal of Universal Computer Science, vol. 30, no. 10 (2024), 1316-1342. DOI:10.3897/jucs.116174.
2. Khadivar, A., Ghale, P. H., & **Lotfi, F.** (2024). A Model to Accepting the Internet of Things by Health Managers in Iran: A Mixed Approach. International Journal of Computer Information Systems and Industrial Management Applications, 16(1), 16-16.

3. A. Atighehchian, T. Alidadi, R. R. Mohammadi, **F. Lotfi**, S. Ajami., "Identifying the Application of Process Mining Technique to Visualise and Manage in the Healthcare Systems." In International Conference on Computer Science, Engineering and Education Applications, pp. 299-308. Cham: Springer Nature Switzerland, 2023.
4. **Lotfi, F.**, K. Fatehi, and N. Badie, "An Analysis of Key Factors to Mobile Health Adoption using Fuzzy AHP", International Journal of Information Technology and Computer Science (IJITCS), Vol.12, No.2, pp.1-17, 2020. ISSN: 2074-9007 (Print), ISSN: 2074-9015 (Onlajn), DOI: 10.5815/ijitcs.2020.02.01.
5. **F. Lotfi** and A. Soleimani, "A Model to Stabilize E-Loyalty to Healthcare Services in the Context of the Internet of Things by using Fuzzy AHP Method," 2020 International Conference on Computation, Automation and Knowledge Management (ICCAKM), Dubai, United Arab Emirates, 2020, pp. 8-13, doi: 10.1109/ICCAKM46823.2020.9051518.
6. Z. Valadkhani, **F. Lotfi**, and B. Rodić, “”A Vision of the Internet of Things: A Review of Critical Challenges,” Int. J. Comput. Inf. Technol., vol. 10, no. 4, 2021, ISSN: 2279-0764, DOI: <https://doi.org/10.24203/ijcit.v10i4.121>.
7. **F. Lotfi** and M. Mansourifard, “Introducing a Model for Customer Satisfaction Based Smart Business Systems”. E-Business Technologies Conference Proceedings, 1(1), 25–30. Retrieved from <https://ebt.rs/journals/index.php/conf-proc/article/view/26>. (2021).
8. **F. Lotfi** and B. Rodić, & Z. Bogdanović, “A System For Monitoring And Managing The Anxiety Among The Young People Using Machine Learning”. E-Business Technologies Conference Proceedings, 2(1), 91–94. Retrieved from <https://ebt.rs/journals/index.php/conf-proc/article/view/96>, June, 2022.

## **Изјава о ауторству**

Име и презиме аутора **Фархад Лотфи**

Број индекса **5027/2021**

Изјављујем

да је докторска дисертација под  
насловом

**Сервиси паметног здравства за мерење и предвиђање стреса студената у**  
**високошколском образовању применом вештачке интелигенције**

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

**Потпис  
аутора**

У Београду, \_\_\_\_\_

**Изјава о истоветности штампане и електронске верзије докторског рада**

Име и презиме аутора **Фархад Лотфи**

Број индекса **5027/2021**

Студијски програм **Електронско пословање и софтверско инжењерство**

Наслов рада **Сервиси паметног здравства за мерење и предвиђање стреса**  
**стулената у високошколском образовању применом вештачке интелигенције**

Ментор **проф. др Зорица Богдановић**

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

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

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

**Потпис  
автора**

У Београду, \_\_\_\_\_

## **Изјава о коришћењу**

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

**Сервиси паметног здравства за мерење и предвиђање стреса студената у високошколском образовању применом вештачке интелигенције**

која је моје ауторско дело.

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

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

1. Ауторство (CC BY)

2. Ауторство – некомерцијално (CC BY-NC)

**(3.) Ауторство – некомерцијално – без прерада (CC BY-NC-ND)**

4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)

5. Ауторство – без прерада (CC BY-ND)

6. Ауторство – делити под истим условима (CC BY-SA)

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

**Потпис аутора**

У Београду, \_\_\_\_\_

\_\_\_\_\_

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