

# Detekcija kognitivne anksioznosti na osnovu snimaka lica snimljenih udaljenom fotopletizmografijom

Tamara Stajić, Milica Janković, član ETRAN i Member, IEEE

**Apstrakt—**Različiti fiziološki signali (srčani ritam, elektrodermalna aktivnost, pritisak zapremine krvi, temperatura itd.) korelišu sa stepenom anksioznosti. Odevni sistemi za merenje fizioloških signala su neudobni jer zahtevaju postavljanje senzora na kožu ispitanika. Beskontaktni sistemi za merenje fizioloških signala omogućavaju nemetljiva merenja. Udaljena fotopletizmografija je beskontaktna metoda koja omogućava merenje srčanog ritma na osnovu video snimaka lica. U ovom radu su uporedene metode detekcije kognitivne anksioznosti sa snimke dobijene udaljenom fotopletizmografijom bazirane na metodama slučajne šume, potpornih vektora i LightGBM. Dobijena tačnost detekcije kognitivne anksioznosti na test skupu je iznosila 78.6% primenom LightGBM klasifikatora.

**Ključne reči—**kognitivna anksioznost; udaljena fotopletizmografija; klasifikacija; segmentacija kože.

## I. UVOD

ANKSIOZNOST je stanje svesti koje uključuje različite psihofizičke komponente: kognitivnu, emocionalnu, bhevioralnu i somatsku [1]. Stanje i nivo anksioznosti se mogu prepoznati na osnovu različitih fizioloških signala (promena u srčanom ritmu, promena pritska zapremine krvi, elektrodermalne aktivnosti, temperature kože itd.) [2].

Srčani ritam je važan indikator psihofizičkog stanja organizma, a parametri varijabilnosti srčanog ritma (eng. *Heart Rate Variability*, HRV) mogu dati značajan uvid u stanje subjekta [3]. HRV vrednosti se konvencionalno mere putem elektrokardiograma (EKG), ali je njegova primenljivost nekomforna u svakodnevnim uslovima zbog potrebe za postavljanjem mernih elektroda na kožu ispitanika.

Procenu srčanog ritma je moguće izvesti i pomoću metode fotopletizmografije (eng. *Photoplethysmography*, PPG) koja se zasniva na merenju pulsa volumena krvi (eng. *Blood Volume Pulse*, BVP). PPG se bazira na detekciji pulsatilne promene apsorpcije svetla na koži – krv upija više svetlosti od okolnog tkiva. U literaturi se navodi da korelacija između HRV parametara određenih korišćenjem EKG-a i korišćenjem PPG-a iznosi do 88% [4]. Udaljena fotopletizmografija (eng. *Remote Photoplethysmography*, rPPG) je nemetljiva beskontaktna metoda koja omogućava merenje srčanog ritma

Tamara Stajić – Elektrotehnički fakultet, Univerzitet u Beogradu, Bulevar Kralja Aleksandra 73, 11020 Beograd, Srbija (e-mail: tasa.stajic@gmail.com).

Milica Janković – Elektrotehnički fakultet, Univerzitet u Beogradu, Bulevar Kralja Aleksandra 73, 11020 Beograd, Srbija (e-mail: piperski@ef.rs)

na osnovu video snimaka lica. Proticanje krvi dovodi do pulsirajuće promene boje kože koja se može snimiti standardnom video kamerom.

Prvi korak u estimaciji srčanog ritma na osnovu rPPG metode obuhvata segmentaciju kože. Potom se iz segmentirane slike ekstrahuje vremenski signal koji predstavlja promenu boje kože. Kako je vremenski signal promene boje kože slabog intenziteta, a snimci sadrže različite artefakte (pomeranje subjekta, promena ambijentalnog osvetljenja, itd.) neophodno je izvršiti njihovo uklanjanje. U literaturi se koriste različiti algoritmi za uklanjanje navedenih artefakata, kao što su analiza osnovnih komponenti [5], analiza nezavisnih komponenti [6], konvolucione neuralne mreže primenjene direkno na sekvencu slika lica subjekta [7]. Konačno, iz ekstrahovanog vremenskog signala iz koga su uklonjeni artefakti, vrši se procena srčanog ritma [8].

U ovom radu, uporedeni su rezultati tri različite klasifikacione metode (slučajne šume - eng. *Random Forest*, metoda potpornih vektora - eng. *Support Vector Machine*, SVM i LightGBM [9]) za detekciju kognitivne anksioznosti na osnovu srčanog ritma ekstrahovanog iz video snimaka lica dostupnih u okviru otvorene baze UBFC-PHYS [10]. Dodatno, испитан је и утицај избора простора боја на резултате сегментације коže, а упоредени су и резултати три методе уklanjanja artefakata iz ekstrahovanih vremenskih signala iz video snimaka (analiza osnovnih komponenti, analiza nezavisnih komponenti i autoenkoder).

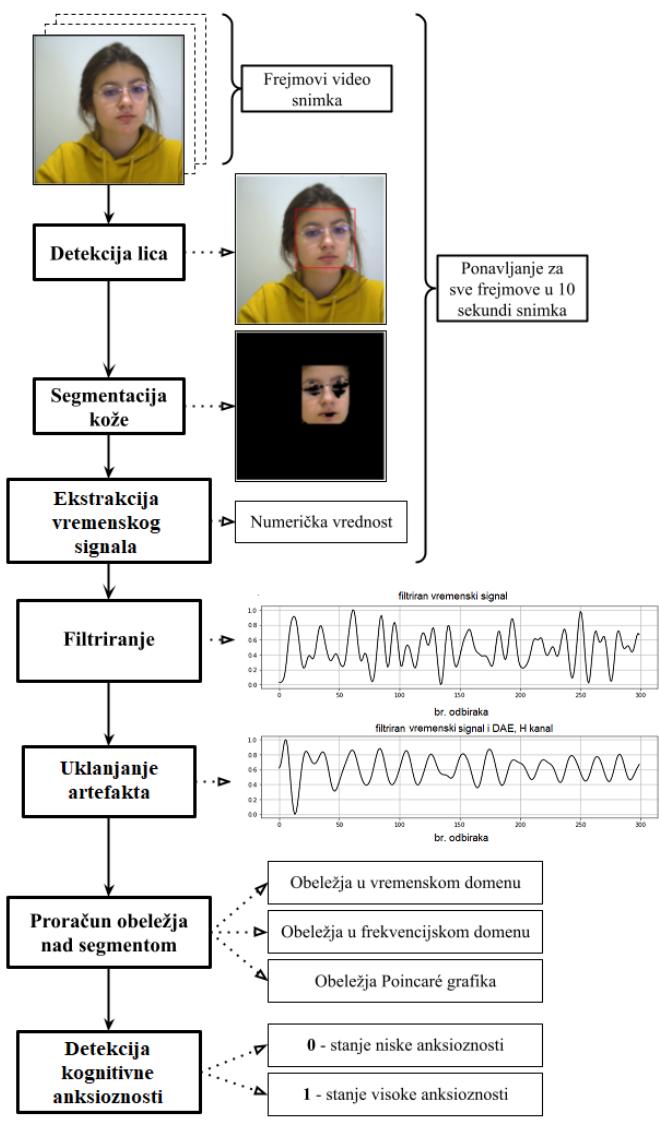
## II. METODOLOGIJA

Blok dijagram algoritma implementiranog u radu je prikazan na Sl. 1. Algoritam obuhvata sledeće korake: 1) detekciju lica, 2) segmentaciju kože, 3) ekstrakciju vremenskog signala, 4) uklanjanje artefakta, 5) procenu srčanog ritma, 6) proračun obeležja, 7) detekciju kognitivne anksioznosti. Implementacija je realizovana u programskom jeziku Python [11].

### A. UBFC-PHYS baza podataka

Baza UBFC-PHYS [10] se sastoji iz: 1) frontalnih snimaka lica ispitanika snimljenih digitalnom kamerom sa rezolucijom 1024x1024 piksela i brzinom od 35 frejmova u sekundi, 2) sinhronizovano merenog pulsa volumena krvi (BVP) i elektrodermalne aktivnosti korišćenjem narukvice Empatica E4 (Empatica Inc., Sjedinjene Američke Države) – u ovom radu je BVP korišćen kao „zlatni standard“, 3) rezultata upitnika u formi Competitive State Anxiety Inventory (CSAI) [12] pomoću koga su ispitanici ocenjivali

kognitivnu anksioznost, somatsku anksioznost i samopouzdanje. Merenja su izvršena nad 56 subjekata starosti 19-38 godina (46 ženskog i 10 muškog pola). U toku eksperimenta su subjekti izvršavali tri različita zadatka (odmaranje – T1, razgovor – T2 i aritmetički zadatak – T3) u trajanju od po 3 minuta. U ovom radu su korišćeni podaci samo za zadatke T1 i T3. Zadatak odmaranja (T1) ne izaziva kognitivnu anksioznost, dok aritmetički zadatak (T3) ima za cilj izazivanje kognitivne anksioznosti kod ispitanika (naglas su vršili oduzimanje brojeva i nakon svake greške bi morali da počnu ponovo). Ispitanici su ocenjivali svoju kognitivnu anksioznost nakon zadataka T1 i T3 ocenama od 1 do 4.



Sl. 1. Blok dijagram implementiranog algoritma

### B. Detekcija lica

Detekcija lica se vrši da bi se u kasnijoj segmentaciji kože izbegle greške koje mogu nastati kada se u okruženju subjekta nalaze objekti u boji sličnoj boji koži. Za detekciju lica se koristi bustovana kaskada sa gradijentnim obeležjima koju su predložili Viola i Džouns 2001. godine [13] baš za primenu na frontalne predstave lica. Glavna prednost ovog algoritma u

odnosu na novije metode jeste brzina izvršavanja, tj. omogućavanje detekcije lica u realnom vremenu.

U ovom radu korišćen je pretrenirani klasifikacioni model ('haarcascade\_frontalface\_default.xml'), dostupan za preuzimanje kao deo biblioteke OpenCV [14]. Detektovanje lica se vrši metodom detectMultiScale() sa parametrima minimalna dimenzija regiona od interesa (60x60px) i faktor skaliranja (1.5).

### C. Segmentacija kože

Zbog svoje jednostavnosti i brzine, za segmentaciju kože odabrana je metoda poređenja intenziteta piksela sa prethodno definisanim pragom. Optimalni pragovi klasifikacije su određeni obučavanjem plitkih stabala odlučivanja nad skupom podataka "Skin Segmentation Data Set" dostupnog na UCI Machine Learning Repository [15] koji se sastoji od piksela razvrstanih u dve klase – koža i ne-koža. Baza se sastoji od 245057 primera, gde svaka instanca predstavlja intenzitet piksela u R (crveno), G (zeleno) i B (plavo) kanalu, zajedno sa binarnim indikatorom koji označava da li piksel pripada koži. 20.75% primera iz skupa podataka pripada koži.

Za obučavanje stabala korišćenja je biblioteka scikit-learn [16]. Stabla su trenirana sa maksimalnom dubinom od 2 i podešenim parametrom za balansiranje podataka.

Proces obučavanja stabala je ponovljen za tri različita prostora boja – RGB, HSV i YCrCb. Evaluacija definisanih stabala je izvršena desetostrukom kros-validacijom i zatim računanjem klasifikacionih metrika na test skupu koji predstavlja 30% celokupnog skupa podataka.

### D. Ekstrakcija vremenskog signala

Dalja analiza je izvršena nad skupom podataka UBFC-PHYS. Radi povećanja brzine izvršavanja algoritma, svi snimci su pre analize smanjeni na dimenzije 480x480px i sačuvani korišćenjem kodeka 'libx264'. Za ovaj proces je korišćena Python biblioteka MoviePy [17].

Za ekstrakciju vremenske serije iz snimaka odabrana je metoda proračuna srednje vrednosti svih piksela koji čine segment kože za svaki frejm video snimka.

### E. Uklanjanje artefakta

Nakon ekstrakcije, signal sa svakog kanala boje je filtriran Butterworth-ovim filtrom propusnikom opsega 1-3 Hz, reda 3 (granične frekvencije su odabrane tako da odgovaraju srčanom ritmu 60-180 otkucaja u minuti). Za implementaciju filtra je korišćena biblioteka scipy [18].

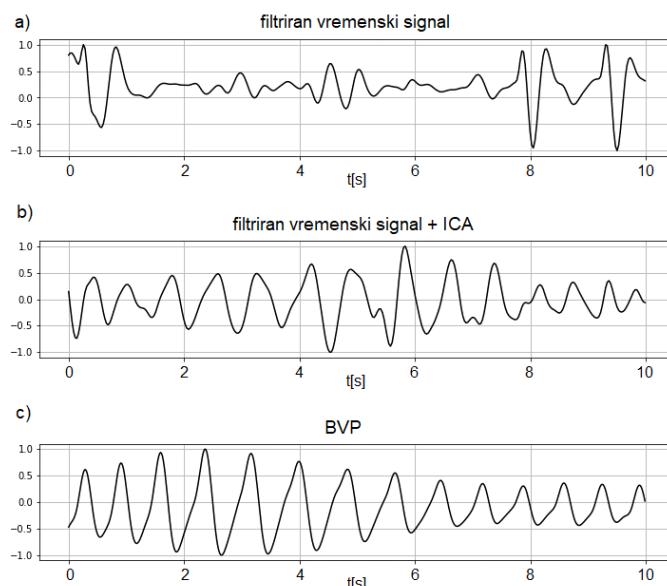
Nakon filtriranja, primenjene su 3 različite metode za uklanjanje artefakta: analiza nezavisnih komponenti (eng. Independent Component Analysis, ICA), analiza osnovnih komponenti (eng. Principal Component Analysis, PCA) i autoenkoder za uklanjanje šuma (eng. Denoising Autoencoder, DAE).

Za implementaciju ICA korišćen je FastICA [19] algoritam, implementiran u biblioteci scikit-learn [16]. Kako se redosled komponenti dobijenih ICA algoritmom ne može utvrditi, u ovom radu se bira ona komponenta čiji spektar ima najveću amplitudu (u opsegu 0.67-3.67 Hz, tj. 40-220 otkucaja u minuti) od svih komponenti. Na Sl. 3. je prikazano poređenje ovako odabrane komponente sa signalom snimljenim

narukvicom (BVP) i signalom nad kojim je izvršeno samo filtriranje filtrom propusnikom opsega.

Za PCA korišćena je implementacija dostupna u biblioteci *scikit-learn* [16].

Autoenkoder za uklanjanje šuma je autoenkoder koji na ulazu dobija korumpirane podatke i treniranje se vrši sa ciljem rekonstrukcije originalnih podataka. U ovom radu je autoenkoder implementiran kao jednodimenzionala konvolucionna mreža, korišćenjem biblioteke *PyTorch* [20]. Korišćen je kernel veličine 35 sa korakom 5 i *LeakyReLU* aktivacionom funkcijom. Treniran je poseban model za svaki od 6 kanala (R, G, B, H, S i V). Modeli su trenirani na snimcima prvih 45 subjekata ( $45 \times 3 \times 18 = 2430$  snimaka) a testiranje je vršeno na preostalih 11 subjekata ( $11 \times 3 \times 18 = 594$  snimaka). Treniranje se vrši 30 epoha i istovremeno se vrši validacija na 10% trening podataka, i kao konačni model se čuva onaj koji ima minimum funkcije gubitka na validacionom skupu. Kao funkcija gubitka korišćena je srednja kvadratna greška.



Sl. 2. a) Filtriran vremenski signal, b) Filtriran vremenski signal sa uklanjanjem artefakta pomoću ICA, c) BVP signal sa narukvice- „zlatni standard“.

#### F. Proračun srčanog ritma

Proračun srčanog ritma je primenjen na ektrahovanom vremenskom signalu očišćenom od artefakta. Vrši se u frekvencijskom domenu pronalaženjem frekvencije na kojoj se nalazi maksimum spektra. Da bi se izbegle prevelike varijacije izazvane lošim kvalitetom signala, maksimalna razlika između dve uzastopne procene je 10 otkucaja u minuti. Koraci u proračunu su sledeći:

1. Uzeti novi signal i proračunati brzu Furijeovu transformaciju
2. Procena srčanog ritma se uzima kao frekvencija na kojoj spektar ima maksimum
3. Ako je razlika ove procene i prethodne veća od 10 otkucaja u minuti, uzeti sledeću maksimalnu vrednost spektra

4. Ako je razlika još uvek veća od 10 otkucaja u minuti, vratiti prethodnu vrednost uvećanu ili umanjenu za 5 (u zavisnosti da li je razlika pozitivna ili negativna).

TABELA II  
PREGLED SVIH OBELEŽJA

| Obeležja u vremenskom domenu     |  |
|----------------------------------|--|
| <i>mean_nni</i>                  | Srednja vrednost RR intervala  |
| <i>sdnn</i>                      | Standardna devijacija intervala između otkucaja  |
| <i>sdsd</i>                      | Standardna devijacija razlika između uzastopnih RR intervala   |
| <i>rmssd</i>                     | Koren sume kvadrata razlika uzastopnih NN intervala  |
| <i>median_nni</i>                | Medijana apsolutnih vrednosti uzastopnih razlika RR intervala  |
| <i>nni_50</i>                    | Broj razlika između uzastopnih RR intervala koje su veće od 50 ms                                      |
| <i>pnni_50</i>                   | Proporcija nni_50 u ukupnom broju RR intervala   |
| <i>nni_20</i>                    | Broj razlika između uzastopnih RR intervala koje su veće od 20 ms                                      |
| <i>pnni_20</i>                   | Proporcija nni_20 u ukupnom broju RR intervala   |
| <i>range_nni</i>                 | Razlika između najvećeg i najmanjeg NN intervala   |
| <i>cvsd</i>                      | Odnos rmssd/ <i>mean_nni</i>   |
| <i>cvnni</i>                     | Odnos sdnn/ <i>mean_nni</i>  |
| <i>mean_hr</i>                   | Srednja vrednost srčanog ritma   |
| <i>max_hr</i>                    | Maksimalna vrednost srčanog ritma  |
| <i>min_hr</i>                    | Minimalna vrednost srčanog ritma   |
| <i>std_hr</i>                    | Standardna devijacija srčanog ritma  |
| Obeležja u frekvencijskom domenu |  |
| <i>total_power</i>               | Spektralna gustina snage (SGS)   |
| <i>vlf</i>                       | SGS u opsegu veoma niskih frekvencija (0.003 – 0.04 Hz)  |
| <i>lf</i>                        | SGS u opsegu niskih frekvencija (0.04 – 0.15 Hz)   |
| <i>hf</i>                        | SGS u opsegu visokih frekvencija (0.15 – 0.4 Hz)   |
| <i>lf_hf_ratio</i>               | Odnos <i>lf/hf</i>   |
| <i>lfnu</i>                      | Normalizovana SGS u opsegu niskih frekvencija  |
| <i>hfnu</i>                      | Normalizovana SGS u opsegu visokih frekvencija   |
| Obeležja Poincaré grafika        |  |
| <i>sd1</i>                       | Standardna devijacija projekcije Poincaré grafika na liniju koja je upravna na liniju identiteta (x=y) |
| <i>sd2</i>                       | Standardna devijacija projekcije Poincaré grafika na liniju identiteta                                 |
| <i>ratio_sd2_sd1</i>             | Odnos između <i>sd1</i> i <i>sd2</i>   |
| <i>csi</i>                       | eng. <i>Cardiac Sympathetic Index</i> , ista definicija kao <i>ratio_sd2_sd1</i>                       |
| <i>cvi</i>                       | eng. <i>Cardiac Vagal Index</i> , $\log_{10}(4\text{sd1} \cdot 4\text{sd2})$                           |
| <i>Modified_csi</i>              | Modifikacija CSI, $(4\text{sd1})^2 / 4\text{sd2}$  |

#### G. Proračun obeležja

Izdvajanje obeležja se vrši na segmentima signala dužine 10 sekundi koji su prethodno filtrirani i na kojima su uklonjeni artefakti. Obeležja su računata korišćenjem biblioteka

*hrvanalysis* [21] i *pyphisi* [22]. Obeležja koja su izdvojena mogu se svrstati u tri kategorije:

### 1. Obeležja u vremenskom domenu

Ova obeležja su bazirana na proračunima vezanim za intervale između otkucaja srca i razlikama između uzastopnih intervala.

### 2. Obeležja u frekvencijskom domenu

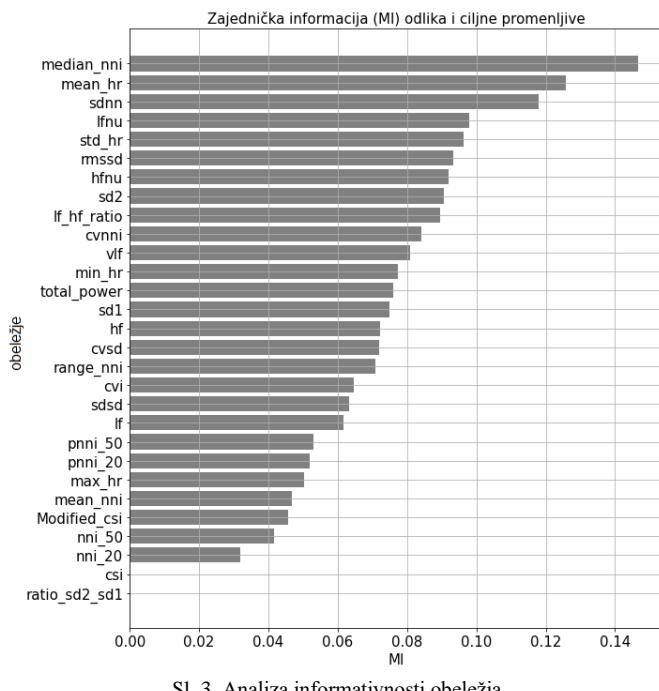
Ova obeležja zasnovana su na spektralnoj gustini snage u različitim frekvencijskim opsezima.

### 3. Obeležja Poincaré grafika

Ova obeležja bazirana su na *Poincaré* grafiku koji predstavlja prikaz RR intervala, gde je svaki RR interval predstavljen kao funkcija prethodnog intervala.

Pregled svih obeležja nalazi se u Tabeli 2. Informativnost ovih obeležja procenjena je korišćenjem zajedničke informacije (eng. *Mutual Information*, MI) između obeležja i ciljne promenljive (u ovom slučaju samoprocena kognitivne anksioznosti subjekata). Rezultat ove analize prikazan je na Sl. 3.

Najinformativnija odlika je medijana dužine intervala između otkucaja, nakon koje slede odlike vezane za srednju vrednost otkucaja srca i standardnu devijaciju intervala izmedju otkucaja. Većina odlika za visokom vrednosti MI su odlike iz vremenskog domena.



Sl. 3. Analiza informativnosti obeležja

### H. Detekcija kognitivne anksioznosti

Za detekciju kognitivne anksioznosti testirana su tri klasifikatora: *Random Forest*, *SVM* i *LightGBM*.

Kako se u skupu podataka nalaze samoprocene subjekata nakon izvršavanja zadatka T1 i T3, za treniranje klasifikatora se razmatra poslednjih 10 segmenata snimka zadatka T1 i poslednjih 10 segmenata snimka zadatka T3 (svaki segment je trajanja 10 sekundi). Ovako definisan skup je podeljen u trening i test skup u odnosu 90:10, 806 odbiraka u trening

skupu i 90 odbiraka u test skupu. Na trening skupu je zatim vršena 10-struka kros-validacija.

S obzirom da su samoprocenjene vrednosti anksioznosti kontinualne, izvršena je diskretizacija kako bi se implementirala binarna klasifikacija. Za graničnu vrednost izabrana je vrednost 2.

## III. REZULTATI I DISKUSIJA

### A. Segmentacija kože

U Tabeli 3. je dato poređenje prostora boja po tačnosti segmentacije piksela kože. Može se zaključiti da se najbolje performanse dobijaju klasifikacijom u HSV prostoru boja (F1 skor 96.6%, tačnost za kros-validaciju 98.4%, tačnost na test skupu 98.5%). Stoga su u nastavku algoritma korišćeni rezultati segmentacije u HSV prostoru boja.

TABELA III  
REZULTATI SEGMENTACIJE KOŽE

| Metrika                 | Način validacije | Prostor boja |              |       |
|-------------------------|------------------|--------------|--------------|-------|
|                         |                  | RGB          | HSV          | YCrCb |
| Tačnost                 | kros-validacija  | 0.900        | <b>0.984</b> | 0.979 |
| Tačnost                 | test skup        | 0.903        | <b>0.985</b> | 0.980 |
| F1 skor                 | test skup        | 0.774        | <b>0.966</b> | 0.953 |
| Prostor ispod ROC krive | test skup        | 0.865        | <b>0.989</b> | 0.987 |

### B. Procena srčanog ritma

U Tabeli 4. je prikazano poređenje metoda korišćenjem dve metrike, korena srednje kvadratne greške (RMSE) i srednje apsolutne greške (MAE). Pri analizi tačnosti treba imati u vidu da je proračun kod DAE izvršen na 11\*3 snimaka (ostatak je korišćen za treniranje klasifikatora), dok je kod ostalih metoda greška računata na svih 56\*3 snimaka. Iz Tabele 4 se može zaključiti da najbolje rezultate u proceni srčanog ritma postiže algoritam koji koristi DAE za otklanjanje artefakata. Međutim, zbog neophodnosti korišćenja većeg dela baze podataka za treniranje enkodera, odabrani su izlazi iz ICA metode za dalje korake algoritma.

Špetlik i dr. [7] su vršili poređenje tačnosti nekoliko algoritama predloženih u literaturi na uniformnom setu kompresovanih snimaka. Pokazali su da je korišćenjem algoritma koji su predložili Wang i dr. [23] najbolji postignut rezultat je RMSE 21.39 i MAE 13.84. Algoritam koji su predložili Haan i Leest [24] postigao je minimum RMSE od 12.45 i MSE od 7.80. Autori za svoj predloženi algoritam (kombinaciju dve konvolucione neuralne mreže, opisano u poglavljju 2.2.2) navode minimalna RMSE od 9.24 i MSE od 7.25. Yu i dr. [25] su uspeli da poboljšaju tačnost na kompresovanim snimcima korišćenjem autoenkodera za uklanjanje šuma treniranog na nekompresovanim slikama – dostignuta je RMSE od 5.93 i MAE od 4.03. Rezultati srednje apsolutne greške korišćenjem DAE navedeni u Tabeli 3. uspevaju da nadmaše prethodno navedene rezultate. Pri poređenju treba imati u vidu da se skupovi podataka koji su korišćeni razlikuju po kvalitetu snimaka i metodi kompresije, kao i načina na koji je vršeno snimanje.

TABELA IV  
REZULTATI DETEKCIJE SRČANOG RITMA

| Uklanjanje artefakta | T1    |             | T3           |             |
|----------------------|-------|-------------|--------------|-------------|
|                      | RMSE  | MAE         | RMSE         | MAE         |
| ICA – HSV            | 13.49 | 7.76        | 15.95        | 11.25       |
| PCA – HSV            | 15.19 | 9.82        | 15.75        | 11.81       |
| DAE - H              | 16.15 | <b>3.69</b> | 14.95        | <b>3.50</b> |
| DAE - S              | 15.09 | <b>3.53</b> | 15.98        | <b>3.60</b> |
| DAE - V              | 16.21 | <b>3.65</b> | <b>14.14</b> | <b>3.42</b> |

### C. Detekcija kognitivne anksioznosti

Najpre je izvršena analiza uticaja broja obeležja na F1 skor pri 10-strukoj kros-validaciji za svaki od klasifikatora pojedinačno. Za slučajne šume, najbolji rezultat je postignut kada se koristi ceo set obeležja, dok je za SVM i *LightGBM* postignut najbolji rezultat kada se koristi 25 obeležja.

Dalje treniranje je vršeno nad najboljim skupom obeležja za svaki klasifikator. Sve metrike su izračunate na 10-strukoj kros-validaciji i dodatno na odvojenom test skupu. Poređenje metrika pri kros-validaciji i na test skupu dato je u Tabeli 5. Najbolji rezultati postignuti su korišćenjem *LightGBM* klasifikatora, sa tačnošću na kros-validaciji od  $67.7 \pm 2.7\%$ . Visoke vrednosti standardne devijacije pri kros-validaciji ukazuju na mali broj obučavajućih podataka.

Pri detekciji stresnih stanja korišćenjem kontaktnih senzora Lee i dr. [26] su dostigli tačnost detekcije stresnog stanja od 85.1% i F1 skor od 84.5%. Koristili su HRV obeležja proračunata na signalu snimljenom Polar H10 pojasom za snimanje srčanog ritma. Pluntke i dr. [27] su naveli tačnost od 88%. Oba rada su vršila klasifikaciju na snimcima dužine 1 minut, dok se u ovom radu vrši na snimcima dužine 10 sekundi što može biti jedan od razloga manje tačnosti.

TABELA V  
POREDENJE KLASIFIKATORA

| Metrika         | Klasifikator        |                    |             |                    |
|-----------------|---------------------|--------------------|-------------|--------------------|
|                 | RandomForest        | SVM                | LightGBM    |                    |
| kros-validacija | <b>F1 skor</b>      | <b>0.576±0.048</b> | 0.529±0.052 | 0.544±0.041        |
|                 | AUC                 | 0.670±0.046        | 0.621±0.059 | <b>0.677±0.027</b> |
|                 | Balansirana tačnost | <b>0.630±0.041</b> | 0.586±0.051 | 0.619±0.028        |
| test            | F1 skor             | 0.674              | 0.585       | <b>0.684</b>       |
|                 | AUC                 | 0.751              | 0.648       | <b>0.786</b>       |
|                 | Balansirana tačnost | 0.714              | 0.634       | <b>0.731</b>       |

U Tabeli 6. su prikazane konfuzione matrice za sva tri primenjena klasifikatora. U matrici konfuzije se može uočiti da su performanse slučajnih šuma i *LightGBM* veoma slične, dok su kod metode potpornih vektora nešto lošije.

Dodatna činjenica koju treba imati u vidu je da su ispitanici davali samo trenutne ocene svog stanja na kraju ispitivanja, te je moguće da njihova ocena nije relevantna tokom celog

perioda. Poboljšanje bi se moglo postići koristeći samo segmente neposredno pred davanja ocene, ali u tom slučaju bi bilo premalo podataka za treniranje klasifikatora.

TABELA VI  
MATRICE KONFUZIJE

|                      |                   | Klasifikovani kao negativni | Klasifikovani kao pozitivni |
|----------------------|-------------------|-----------------------------|-----------------------------|
| <i>Random Forest</i> | Stvarno negativni | 33                          | 22                          |
|                      | Stvarno pozitivni | 6                           | 29                          |
| <i>SVM</i>           | Stvarno negativni | 32                          | 23                          |
|                      | Stvarno pozitivni | 11                          | 24                          |
| <i>LightGBM</i>      | Stvarno negativni | 38                          | 17                          |
|                      | Stvarno pozitivni | 8                           | 27                          |

Meziati Sabour i dr. [10] su vršili detekciju anksionih stanja korišćenjem rPPG na istoj bazi snimaka *UBFC-PHYS* koja je korišćena i u ovom radu. Odbačeni su snimci kod kojih je uočen smanjen kvalitet referentnog BVP signala (snimljenog putem narukvice). Analiza je vršena na nekompresovanim snimcima, na segmentima dužine 30 sekundi. Maksimalna dostignuta tačnost je 69.83% korišćenjem metode SVM sa linearnim kernelom. Takođe je izvršena analiza tačnosti klasifikacije korišćenjem referentnih BVP snimaka, gde je maksimalna dobijena tačnost 62.27%. S obzirom da su klase nebalansirane, a vrednosti F1 skora i balansirane tačnosti nisu navedene, teško je izvršiti direktno poređenje rezultata.

### IV. ZAKLJUČAK

U radu je opisan algoritam za detekciju kognitivne anksioznosti sa snimaka lica korišćenjem obeležja varijabilnosti srčanog ritma dobijenog metodom udaljene fotopletizmografije. Primenjena tri klasifikatora (slučajne šume, metoda potpornih vektora i *LightGBM*) uspevaju da prepoznaju postojanje anksioznosti na segmentima signala od 10 s, sa tačnošću na test skupu od 78.6%. Do poboljšanja klasifikacije bi se moglo doći dodavanjem dodatnih primera snimaka na kojima su ispitanici u stanju visoke anksioznosti. Dodatno poboljšanje moglo bi se dobiti korišćenjem dužih segmenata signala za ekstrakciju obeležja varijabilnosti srčanog ritma (ovo bi smanjilo broj odbiraka u obučavajućem skupu klasifikatora, te bi bilo neophodno proširiti polazni set podataka). Radi daljeg razvoja potrebno je ponoviti polazni eksperiment sa više učesnika i boljom kontrolom kvaliteta referentnog signala. Nakon dostizanja zadovoljavajuće tačnosti klasifikacije, moguće je razviti program koji će putem kamere na laptop računaru detektovati kada se korisnik nađe u stanju visoke kognitivne anksioznosti.

### ZAHVALNICA

Ovo istraživanje je bilo delimično pomognuto od strane Ministarstva nauke i tehnološkog razvoja Republike Srbije (br. ugovora 451-03-47/2023-01/200103).

## LITERATURA

- [1] D. Sarkar, "A review of behavioral tests to evaluate different types of anxiety and anti-anxiety effects", *Clinical Psychopharmacology and Neuroscience* vol. 18, no. 3, pp. 341-351, 2020.
- [2] J. Šalkevičius, R. Damaševičius, R. Maskeliunas i I. Laukienė, "Anxiety level recognition for virtual reality therapy system using physiological signals", *Electronics*, vol. 8, no. 9, pp. 1039, 2019.
- [3] M. Egger, M. Ley i S. Hanke, "Emotion Recognition from Physiological Signal Analysis: A Review," *Electronic Notes in Theoretical Computer Science*, pp. 35-55, 2019.
- [4] N. Pinheiro, R. Couceiro, J. Henriques, J. Muehlsteff, I. Quintal, L. Goncalves i P. Carvalho, "Can PPG be used for HRV analysis?", u *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, pp. 2945-2949, 2016.
- [5] M. Lewandowska, J. Ruminski, T. Kocejko i J. p. r. Nowak, "Measuring pulse rate with a webcam non-contact method for evaluating cardiac activity," *Proc. Federated Conference on Computer Science and Information Systems (FedCSIS)*, 8-11 September, Szczecin, Poland, pp. 405-410, 2011.
- [6] M. Poh, D. McDuff i R. Picard, "Advancements in Noncontact, Multiparameter Physiological Measurements Using a Webcam," *IEEE Transactions on Biomedical Engineering*, pp. 7-11, 2011.
- [7] R. Spetlik, J. Cech, V. Franc i J. Matas, "Visual heart rate estimation with convolutional neural network," in *Proceedings of the british machine vision conference*, Newcastle, pp. 1-12, 2018.
- [8] T. Stajić, "Prepoznavanje nivoa anksioznosti na osnovu slike lica", master rad, Univerzitet u Beogradu – Elektrotehnički fakultet, 2022.
- [9] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye i T.Y. Liu, "Lightgbm: A highly efficient gradient boosting decision tree," *Advances in neural information processing systems*, pp. 3146–3154, 2017.
- [10] R. Meziati Sabour, Y. Benbezeth, D. De Oliveira, J. Chappe i F. Yang, "UBFC-Phys: A Multimodal Database For Psychophysiological Studies Of Social Stress," *IEEE Transactions on Affective Computing*, pp. 1-16, 2021.
- [11] G. Van Rossum i J. De Boer, "Interactively Testing Remote Servers Using the Python Programming Language," *CWI Quarterly*, pp. 283-303, 1991.
- [12] R. Martens, D. Burton, R.S. Vealey, L.A. Bump i D.E Smith, "Development and Validation of the Competitive State Anxiety Inventory-2 (CSAI-2)," *Journal of Sport & Exercise Psychology*, pp. 117-190, 1982.
- [13] P. Viola i M. Jones, "Rapid Object Detection using a Boosted Cascade of Simple Features," *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, 8-14 December, Kauai, HI, USA, pp. 511-518, 2001.
- [14] G. Bradski, "The OpenCV Library," OpenCV team, 2000.
- [15] R. Bhatt i A. Dhall, "Skin Segmentation," UCI Machine Learning Repository, 2012.
- [16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot i E. Duchesnay, "Scikit-learn: Machine Learning in Python," *JMLR*, pp. 2825-2830, 2011.
- [17] Zulko, "MoviePy," [Izvor na internetu]. Dostupno na: <https://github.com/Zulko/moviepy>. [Pristupljeno 7.5.2023].
- [18] P. Virtanen i dr, "SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python," *Nature Methods*, pp. 261-272, 2020.
- [19] A. Hyvärinen, "Fast and Robust Fixed-Point Algorithms for Independent Component Analysis," *IEEE Transactions on Neural Networks*, pp. 626-634, 1999.
- [20] A. Paszke i dr, "PyTorch: An Imperative Style, High-Performance Deep Learning Library," *Advances in Neural Information Processing Systems*, pp. 8024-8035, 2019.
- [21] R. Champseix, "hrv-analysis," Aura Healthcare, 2018. [Izvor na internetu]. Dostupno na: <https://aura-healthcare.github.io/hrv-analysis/readme.html>. [Pristupljeno 7.5.2023].
- [22] A. Bizzego, A. Battisti, G. Gabrieli, G. Esposito i C. Furlanello, "pyphysio: A physiological signal processing library for data science approaches in physiology," *SoftwareX*, vol. 10, pp. 100287, 2019.
- [23] W. Wang, S. Stuijk i G. d. Haan, "A Novel Algorithm for Remote Photoplethysmography: Spatial Subspace Rotation," *IEEE transactions on biomedical engineering* 63, pp. 1974-1984, 2015.
- [24] G. De Haan i A. Van Leest, "Improved motion robustness of remote-ppg by using the blood volume pulse signature," *Physio. Meas.*, pp. 1-14, 2014.
- [25] Z. Yu, W. Peng, X. Li, X. Hong i G. Zhao, "Remote heart rate measurement from highly compressed facial videos: an end-to-end deep learning solution with video enhancement," u *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Seoul, pp. 151-160, 2019.
- [26] S. Lee, H. Hwang, S. Park, S. Kim, J. Ha, Y. Jang, S. Hwang, H.-K. Park, J. Lee i I. Kim, "Mental Stress Assessment Using Ultra Short Term HRV Analysis Based on Non-Linear Method," *Biosensors*, vol. 12, no. 7, 465, 2022.
- [27] U. Plunck, S. Gerke, A. Sridhar, J. Weiss i B. Michel, "Evaluation and Classification of Physical and Psychological Stress in Firefighters using Heart Rate Variability," u *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 23-27 July, Berlin, pp. 2207-2212, 2019.

## ABSTRACT

Various physiological signals (heart rate, electrodermal activity, blood volume pressure, temperature, etc.) correlate with the anxiety level. Wearable systems for measuring physiological signals are inconvenient because they require the sensors placement on the subject's skin. Non-contact systems for measuring physiological signals enable unobtrusive measurements. Remote photoplethysmography is a non-contact method that allows measurement of heart rhythm based on facial video recordings. In this paper, cognitive anxiety detection methods applied on images obtained by remote photoplethysmography based on Random Forest, Support Vector Machine and LightGBM methods were compared. Obtained accuracy of cognitive anxiety detection on the test set was 78.6% using the LightGBM classifier.

**Detection of cognitive anxiety based on facial images from remote photoplethysmography**

Tamara Stajić i Milica Janković