

SUSTAV ZA UDALJENO MJERENJE SRČANOG RITMA POMOĆU KOMERCIJALNE KAMERE

A SYSTEM FOR REMOTE HEART RATE MEASUREMENT USING A CONSUMER CAMERA

Marko Horvat¹, Denis Fodor²

¹Tehničko veleučilište u Zagrebu, Zagreb, Hrvatska

²Ars Futura d.o.o., Zagreb, Hrvatska

Sažetak

Učinkovit i nenametljiv postupak mjerjenja srčanog ritma može biti izrazito koristan kao pomoć pri brzoj procjeni fizičkog i mentalnog stanja. Prvenstveni cilj ovog rada je predstaviti računalni sustav, razvijen od strane autora, za udaljeno mjerjenje srčanog ritma pomoću obične komercijalne kamere. Osim za brzu procjenu fizičkog stanja, računalni sustav može se koristi u sprezi s bazama afektivne multimedije za različite oblike psihoterapije kao što je biofeedback ili kognitivno-bihevioralna terapija. Sustav koristi biblioteku otvorenog koda OpenCV kako bi se obradom signala iz slike lica procijenila vrijednost srčanog ritma ispitanika. Svi podaci se pohranjuju u relacijsku bazu podataka za kasniju analizu. Klijentski segment sustava je potpuno mobilan. Točnost sustava ispitana je u eksperimentu. Dobiveni rezultati ukazuju da se ovakva tehnologija može uspješno koristiti za mjerjenje srčanog ritma u stanju mirovanja, dok su potrebne daljnje optimizacije za mjerjenje tijekom ili nakon fizičkih aktivnosti.

Ključne riječi: srčani ritam, fotoplethysmograf, računalni vid, OpenCV, biofeedback

Abstract

An effective and unobtrusive procedure for measuring heart rate can be extremely useful as an aid in rapid assessment of physical and mental condition. The primary aim of this paper is to present a computer system, developed by the authors, for remote heart rate measurement using a commercial camera.

Except for a quick assessment of the physical condition, the computer system can be used in conjunction with affective multimedia databases for different forms of psychotherapy such as biofeedback or cognitive-behavioral therapy. The system utilizes the OpenCV open-source library to estimate the heart rate by processing subject's facial images. All data is stored in the relational database for later analysis. The client segment of the system is completely mobile. System accuracy was evaluated in an experiment. The results indicate that this technology can be successfully used to measure heart rate in a rest state, while further optimization is required for measurement during or after physical activities.

Keywords: heart rate, photoplethysmograph, computer vision, OpenCV, biofeedback

1. Uvod

1. Introduction

Svakim danom pronalaze se nove primjene neinvazivnih postupaka mjerjenja numeričkih vrijednosti fizioloških parametara kao što su disanje, srčani ritam, temperatura kože, elektrokardiogram (EKG) i elektroencefalogram (EEG). Određivanje broja otkucaja srca važan je fiziološki čimbenik pri određivanju zdravlja i općenitog fizičkog stanja. Današnji pametni satovi i drugi uređaji potrošačke elektronike uključuju mogućnost praćenja osnovnih parametara zdravlja korisnika [1]. Takvi uređaji omogućuju praćenje barem srčanog ritma, a često i vodljivosti kože (engl. galvanic skin response, GSR), kao važnijih parametara za praćenje zdravstvenog stanja [1].

S druge strane, precizni i pouzdani medicinski uređaji su većih dimenzija i mase, nisu namijenjeni korištenju u pokretu, te na sebi uključuju i jedinice za prikaz fizioloških parametara (npr. ekran ili pisač).

U ovom radu autori su razvili računalni sustav za udaljeno mjerjenje srčanog ritma pomoću kamere. Sustav je dizajniran za kontinuiran rad i uporabu komercijalnih kamera relativno niske rezolucije. Prikupljeni podaci su vremenski označeni i u stvarnom vremenu pohranjuju se u relacijsku bazu sustava. Makar sustav radi s jednim korisnikom ne postoje tehničke prepreke za procjenu srčanog ritma više korisnika istodobno.

2. Neinvazivni postupci mjerjenja srčanog ritma

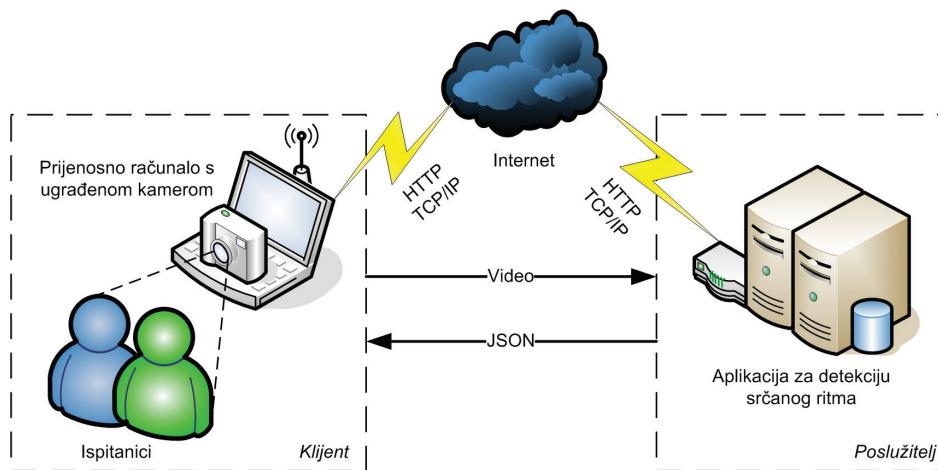
2. Non-Invasive Heart Rate Measurement Procedures

Krv, uz ostale tvari, sadrži krvni pigment hemoglobin koji na sebe veže kisik, a on uzrokuje promjenu boje krv. Hemoglobin je vrsta proteina koji u svojoj strukturi sadrži željezo. Nalazi se u crvenim krvnim stanicama. Hemoglobin služi za prijenos kisika od pluća prema ostatku tijela gdje se kisik otpušta te omogućuje rad mišića i svih organa [2]. Hemoglobin koji prenosi kisik zove se oksihemoglobin, dok onaj koji prenosi ugljikov dioksid zove se karbaminohemoglobin. Kada krv teče iz srca kroz tijelo onda sadrži hemoglobin s kisikom (HbO_2) i krv daje svjetlocrvenu boju, a kad teče natrag prema srcu onda sadrži hemoglobin bez kisika (Hb) i ima tamnocrvenu boju [3]. Maksimum apsorpcije hemoglobina je između 530 i 590 nanometara (nm) što odgovara zelenoj boji, odnosno zelenom kanalu u slici [2][3].

Pulsna oksimetrija (engl. pulse oximetry) je neinvazivna metoda mjerjenja oksigenacije ili postotka hemoglobina koji je zasićen kisikom (engl. saturation of peripheral oxygen, SpO_2). Senzor se najčešće postavlja na vrh prsta ili na ušnu resicu, a sastoji se od dva izvora svjetla valnih duljina 650 nm i 805 nm koji se djelomično apsorbiraju u hemoglobinu proporcionalno razini zasićenosti kisikom. Računajući apsorpciju na dvjema valnim duljinama moguće je odrediti zasićenost hemoglobina kisikom.

Ova metoda ovisi o protoku krvи koji je nužan za njeno funkcioniranje jer kada ga nema ili je oslabljen oksimetar neće raditi. U pravilu, oksimetri su točni rasponu od 70 do 100% zasićenosti kisikom (unutar greške od ~2%), ali ispod 70% točnost im je bitno manja. Općenito možemo reći da se postupak pulsne oksimetrije temelji na dva principa: 1) oksihemoglobin i deoksihemoglobin razlikuju se po razini apsorpcije crvenih i infracrvenih zraka (metoda spektrofotometrije), te 2) količina arterijske krvi u tkivu (pa prema tome i apsorpcije svjetla kroz krv) mijenja se tijekom pulsacije [4][5].

Pletizmografija (engl. plethysmography) je jedna od medicinskih metoda pulsne oksimetrije koja služi za detekciju promjene volumena dijela tijela uzrokovanoj promjenom veličine protoka krvi [4]. To je također neinvazivna metoda, vrlo jednostavna za implementaciju i široko korištena. Pletizmografski signali omogućuju mjerjenje srčanog ritma, a mogu se detektirati različitim postupcima. Pletizmografski signali ukazuju na arterijsku krv koja prenosi kisik kroz tijelo jer ona više apsorbira svjetlost nego okolno tkivo. Važno je napomenuti da se ovim signalima može pratiti i razina zasićenja krvи kisikom jer krv bogata kisikom i krv sa nižom razinom kisika nemaju istu boju. Pletizmografija u praksi se temelji na mjerjenju razlike intenziteta infracrvene zrake koja prolazi kroz kožu i tkivo pomoću fotodetektora ili kamere. U tipičnom fotopletizmografskom senzoru nalaze se LED diode koje su pogonjene oscilirajućim sinusnim signalom vrlo stabilne amplitude. Budući da koža dobro provodi infracrvene valne duljine apsorpcija je najveća u krvnim žilama, a najmanja u tkivu. Signal dobiven u fotodetektoru proporcionalan je promjeni volumena krvnih žila. Tako dobiva informacija ovisi o srčanom ritmu i krvnom tlaku. Ako je u nekom vremenskom razdoblju krvni tlak konstantan fotopletizmografski senzor može se koristiti za neposredno i brzo mjerjenje srčanog ritma.



Slika 1 Arhitektura sustava za udaljeno mjerjenje srčanog ritma korištenjem kamere

Figure 1 Architecture of the system for remote heart rate measurement using camera

3. Primjena udaljenog mjerjenja srčanog ritma

3. Remote heart rate measurement usage

Postupak udaljenog mjerjenja srčanog ritma pomoću kamere ima tri bitna svojstva:

1. Mjerenje je beskontaktno (bežično)
2. Mjerenje se može vršiti kontinuirano i kroz duže vremensko razdoblje
3. Moguće je istodobno mjerjenje više osoba unutar vidnog polja kamere

Ova svojstva čine udaljeno mjerjenje vrlo pogodnim za primjenu u postupcima biofeedbacka [5] i neurofeedbacka [6], a također i u terapiji izlaganjem, odnosno srodnim ili izvedenim terapijama. Biofeedback je terapeutski postupak za liječenje mentalnih poteškoća uzrokovanih stresom kao što su strah, tjeskoba, trema, umor, nedostatak koncentracije i nervozni [1]. Prema literaturi [1]

Biofeedback je proces ili tehnika svojevoljnog učenja kontrole nad automatskim, refleksno-kontroliranim tjelesnim funkcijama“. Uspješnost biofeedbacka ovisi o računalnim sustavima za mjerjenje fizioloških parametara i generiranje multimedijiskih pobuda [1][5][6][7].

Terapija izlaganjem (engl. Exposure therapy, ET) je često korišten oblik kognitivno-bihevioralne psihoterapije (engl. Cognitive behavioral therapy, CBT) s ciljem mijenjanja osobnih stavova, očekivanja, vjerovanja i drugih elemenata kognicije, a koristi se za smanjenje straha i anksioznosti.

U bihevioralnom dijelu može koristiti multimedijiske pobude i fiziološke podatke za točniju procjenu afektivnog stanja [8]. U posljednjih desetak godina ubrzano se razvijaju računalni sustavi sa potporom za prividnu stvarnost (VR) i psihofiziološka mjerjenja. Takvi sustavi uspješno se koriste u liječenju negativnih psiholoških posljedica borbe kao što je posttraumatski stresni poremećaj (PTSP) (npr. [9][10][11]). Računalni sustavi koriste se i u CBT postupcima nad vojnim osobljem [12]. Zbog svoje rastuće popularnosti CBT spregnut s računalnim sustavima smatra se zasebnom podvrstom CBT-a, te se računalno potpomognut CBT (engl. Computerized CBT, CCBT) [13]. Trenutno najčešće korišteni oblik CBT za prevenciju mentalnih bolesti i poteškoća izazvanih stresom je dozirano izlaganje stresu (engl. Stress inoculation training, SIT) [14].

4. Sustav za udaljeno mjerjenje srčanog ritma korištenjem kamere

4. System for remote heart rate measurement using camera

Za potrebe ovog rada izrađena je višeslojna računalna aplikacija, odnosno informacijski sustav, za udaljeno mjerjenje srčanog ritma korištenjem kamere. Za izvedbu sustava korištene su raznovrsne računalne tehnologije i alati: programski jezici HTML, Python i JavaScript, radni okvir za razvoj grafičkog korisničkog sučelja PyQt5, biblioteka otvorenog koda za računalni vid OpenCV, biblioteka otvorenog koda za numeričke postupke NumPy,

višeplatformsko izvršno okruženje otvorenog koda Node.js, radni okvir za ubrzani razvoj snažnih web aplikacija Express, Handlebars predložak za dinamičko generiranje HTML izvornog programskog koda, Pm2 upravitelj procesa za Node.js izvršno okruženje, HTTP posrednički poslužitelj otvorenog koda NGINX, alat za razvoj aplikacijskih programskega sučelja (engl. Application Programming Interface, API) Postman, Homebrew alat za instalaciju programskih paketa, relacijski sustav za upravljanje bazom podataka (engl. Relational Database Management System, RDBMS) MySQL, te Ubuntu Linux poslužitelj. Pojednostavljen prikaz arhitekture izrađene aplikacije prikazan je na Slici 1.

Aplikacija ima arhitekturu tipa klijent-poslužitelj. Na strani klijenta unutar mrežnog preglednika izvršava se JavaScript Node.js aplikacija koja upravlja kamerom i šalje tok multimedijskih podataka prema poslužitelju. Klijentska aplikacija na zahtjev korisnika samostalno uključuje kameru ugrađenu ili priključenu na klijentsko računalo, sa kamere prima sliku u bliskom stvarnom vremenu, te šalje dobivene multimedijiske podatke prema poslužitelju. Na poslužitelju se izvršava poslužiteljska aplikacija pisana u Pythonu.

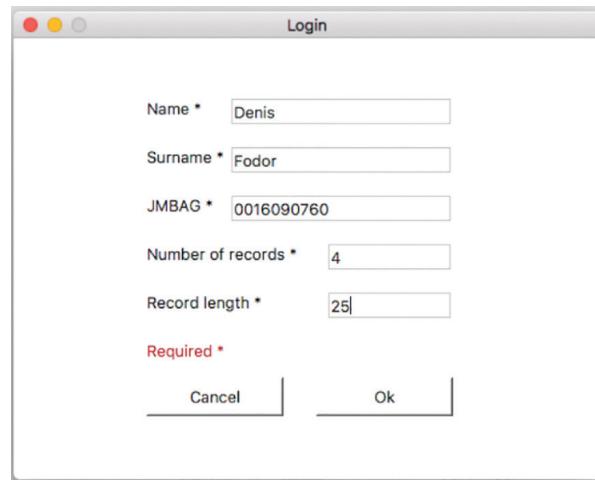
Aplikacija vrši procjenu srčanog ritma iz slike, statistički obrađuje i formira rezultate koji se potom dostavljaju klijentu u JSON formatu putem HTTP protokola. Potom klijent parsira (raščlanjuje) tako dobivenu datoteku i prikazuje dobivene podatke u grafičkom korisničkom sučelju. Sve aktivnosti (koraci) u procjeni srčanog ritma iz video slike dobivene kamerom, a koji su implementirani u računalnom sustavu, prikazani su UML dijagramom aktivnosti na Slici 2.

Na Slici 3 je prikazan početni ekran klijentske aplikacije koji služi za unos podataka o korisniku prije početka nove sesije.



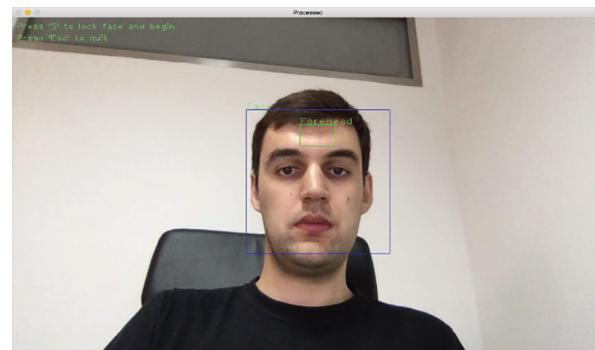
Slika 2 Aktivnosti procjene srčanog ritma implementirane u sustavu

Figure 2 Heart rate estimation activities implemented in the system



Slika 3 Početni ekran klijentske aplikacije

Figure 3 Client application's home



Slika 4 Početni ekran klijentske aplikacije

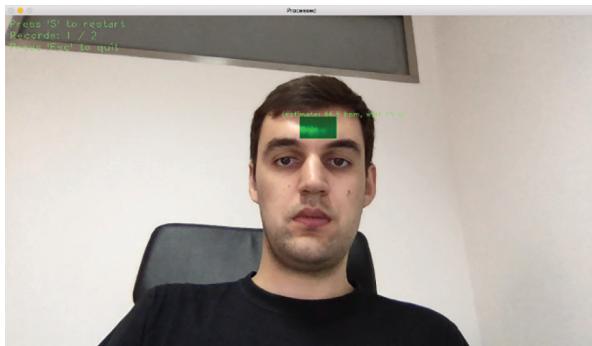
Figure 4 Client application's home

Vidljivo je da je to minimalno grafičko sučelje koje ima nekoliko polja za unos koje predstavljaju informacije o korisniku te informacije o broju, odnosno trajanju svakog mjerjenja unutar sesije. Savjetuje se da korisnik prilikom svake prijave unese isti JMBAG budući da on služi kao identifikator za tog korisnika i preko njega se kasnije u web aplikaciji mogu vidjeti svi detalji o sesijama, odnosno snimkama unutar sesije. Sve podatke je potrebno unijeti jer u suprotnom korisnik ne može doći do ekrana za snimanje.

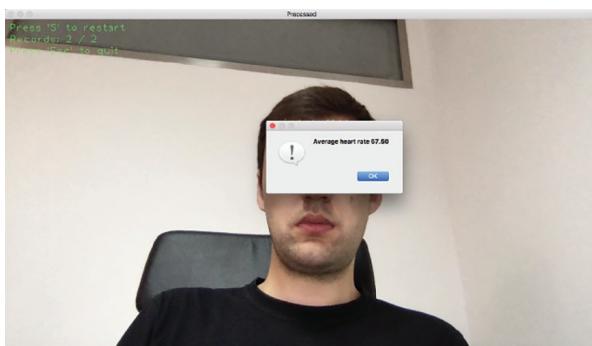
Nakon što se korisnik uspješno prijavio u aplikaciju prikazuje mu se ekran kao na Slici 4, te je stvorena nova sesija s kojom će se snimke povezivati.

Korisnik mora pričekati nekoliko trenutaka da kamera pronađe njegovo lice, odnosno da se izolira područje na čelu s kojeg će biti prikupljene informacije tijekom snimanja. Zatim može započeti snimanje.

Važno je da se tijekom mjerjenja srčanog ritma ispitanik ne pomiče, odnosno treba ostati što je moguće mirniji kako bi mjerjenje bilo točnije. Zbog slučaja kada korisnik započne snimanje, odnosno mjerjenje srčanog ritma, a informacije na ekranu se izmjene, dodana nova kontrola koja se aktivira pritiskom na slovo 'S' za ponovno pokretanje trenutnog snimanja. Ova opcija se koristi ako korisnik smatra da nije bio dovoljno miran tijekom snimanja, budući da je to jedan od glavnih uvjeta da podaci prikupljeni samim snimanjem budu što točniji. Također, na ekranu je vidljiva informacija koliko snimaka u toj sesiji ukupno ima te koja snimka u sesiji je trenutno aktivna. Nova sesija je kreirana svaki put kada se korisnik prijavi u aplikaciju. Isto tako na ekran se dodaje podatak koliko vremena je još preostalo do završetka snimanja, te procijenjeni srčani ritam koji se prikuplja u stvarnom vremenu i oni se konstantno ažuriraju na ekranu.



Slika 5 Ekran klijentske aplikacije tijekom mjerjenja
Figure 5 Client application screen during the measurement



Slika 6 Ekran klijentske aplikacije nakon završene sesije
Figure 6 Client application screen after the measurement has ended

Slika 5 prikazuje ekran tijekom snimanja gdje možemo sve navedene informacije.

Nakon što su sve snimke odradene i sesija je završena, korisniku se prikazuje informacija o tome koliki mu je izmjereni prosječni srčani ritam. Na Slici 6 je primjer završenog snimanja i prikaza procijenjene vrijednosti srčanog ritma.

5. Ispitivanje točnosti mjerjenja srčanog ritma korištenjem kamere

5. System for remote heart rate measurement using camera

Točnost mjerjenja sustava ispitan je pomoću N=3 osoba i dva skupa istih testova. Prvi test je mjerjenje srčanog ritma u stanju mirovanja, dok je drugi test napravljen nakon kraće fizičke aktivnosti. U testovima je za usporedbu bila korištena Android mobilna aplikacija „Instant Heart Rate“ [15].

Ova mobilna aplikacija je odabrana jer je vrlo često korištena u praksi, ima vrlo dobre i izvrsne ocjene od strane korisnika i često se ističe njezina praktičnost i točnost mjerjenja u usporedbi sa drugim mobilnim aplikacijama slične svrhe. Tablica 1 prikazuje prikupljene rezultate u stanju mirovanja, dok Tablica 2 prikazuje srčani ritam nakon kraće fizičke aktivnosti, točnije 15 odradenih čučnjeva. Duljina jednog mjerjenja web aplikacije je 20 sekundi, dok mobilna aplikacija srčani ritam izmjeri kroz otprilike 15 sekundi i to tako da se kažiprst stavi na kameru. Izrađena klijent-server aplikacija za udaljeno mjerjenje srčanog ritma pomoću kamere označena je kao „App1“, a mobilna aplikacija za usporedbu „App2“.

Analizirajući dobivene podatke u dvije tablice može se zaključiti da su rezultati testiranja gotovo jednaki kada se osoba nalazi u stanju mirovanja gdje srednja greška svih mjerjenja iznosi 4,13%. S druge strane, nakon što osoba poveća svoj puls nekom fizičkom aktivnošću, vidimo da je razlika između srčanih ritmova desktop i mobilne aplikacije prilično velika. U ovom slučaju prosječna ukupna pogreška raste na vrlo visokih 38,75%.

Tablica 1. Mjerenje srčanog ritma u stanju mirovanja. Relativna greška (%) je prikazana ispod vrijednosti pulsa.
Table 1. Heart rate measurement in rest state. Relative error (%) is shown under pulse values.

Osoba 1		Osoba 2		Osoba 3	
App1	App2	App1	App2	App1	App2
65	63	67	65	68	65
3,07%		2,98%		4,41%	
60	62	57	64	64	66
3,33%		12,28%		3,12%	
62	60	62	63	63	61
3,23%		1,61%		3,17%	

Tablica 2. Mjerenje srčanog ritma nakon fizičke aktivnosti. Relativna greška (%) je prikazana ispod vrijednosti pulsa.

Table 2. Heart rate measurement after physical activity. Relative error (%) is shown under pulse values..

Osoba 1		Osoba 2		Osoba 3	
App1	App2	App1	App2	App1	App2
65	63	67	65	68	65
3,07%		2,98%		4,41%	
60	62	57	64	64	66
3,33%		12,28%		3,12%	
62	60	62	63	63	61
3,23%		1,61%		3,17%	

6. Zaključak

6. Conclusion

Sustav za udaljeno praćenje srčanog ritma svojim načinom rada ne ometa korisnike u njihovim aktivnostima. Svojim načinom rada predstavljeni sustav može kontinuirano pratiti jednog ili više korisnika, te pohranjivati podatke o njihovom srčanom ritmu u relacijsku bazu podataka bežičnom komunikacijom sa poslužiteljem. Korištenjem sustava moguće je procijeniti osnovno zdravstveno stanje korisnika. Ovisno o načinu uporabe – primjerice ako su korisnici izloženi emocionalnim pobudama ili obavljaju kognitivne zadatke opažanja, situacijske svjesnosti ili donašanja odluka – moguće je procijeniti afektivno stanje pa čak i kognitivnu sposobnost korisnika. Ovakav sustav nije bez nedostataka. Relativni položaj korisnika i kamere uvelike utiče na točnost mjerenja.

U idealnom slučaju kamera se mora nalaziti ispred korisnika i korisnici se moraju što manje pomicati tijekom mjerenja što nije uvijek moguće ostvariti.

Što se tiče testiranja sustava za udaljeno mjerenje srčanog ritma korištenjem kamere, moguće je donijeti nekoliko zaključaka. Naime, čini se da je procjena srčanog ritma donekle točna kada se on mjeri osobi koja se nalazi u stanju mirovanja jer razlika između vrijednosti izrađene klijent-server aplikacije i mobilne aplikacije za testiranje nije bile značajna. S druge strane, kada je riječ o procjeni srčanog ritma osobe nakon fizičke aktivnosti, čini se da tu mjerenje nije najpreciznije budući da su razlike prilično velike, i tu sigurno ima mjesta za poboljšanje i napredak u točnosti udaljenog mjerenja srčanog ritma pomoću kamere.

Motivacija za izradu ovog sustava bila je želja za razvojem neinvazivnog i jeftinog načina za praćenje srčanog ritma koji se može koristiti kroz duže vremensko razdoblje i nad više korisnika istodobno. Ovakav sustav u budućnosti je moguće integrirati u širi sustav za personalizirano praćenje zdravlja osoba.

7. REFERENCE

7. REFERENCES

- [1] Pejak, I., Otočan, D., & Horvat, M. (2017). Application of Android Wear smartwatches with photoplethysmographic sensors in biofeedback therapy. Polytechnic and Design, 5(2), 133-141.
- [2] Schechter, A. N. (2008). Hemoglobin research and the origins of molecular medicine. Blood, 112(10), 3927-3938.
- [3] Philips Medical Systems. Understanding Pulse Oximetry SpO2 Concepts http://incenter.medical.philips.com/doclib/enc/fetch/586262/586457/Understanding_Pulse_Oximetry.pdf?%3Fnodeid%3D586458%26vernum%3D2, dohvaćeno 10. lipnja 2018.
- [4] Nikolić, D., Zoltan, H., Popović, V., Pasternak, J., Kaćanski, M., & Basta, M. (2009). Digitalna fotopletizmografija u dijagnostici venske tromboze donjih ekstremiteta. Medicina danas, 8(4-6), 157-166.

- [5] Schwartz, M. S., & Andrasik, F. (Eds.). (2017). *Biofeedback: A practitioner's guide*. Guilford Publications.
- [6] Horvat, M., Dobrinić, M., & Novosel, M. (2017). Computer systems for multimedia stimuli generation in psychotherapy. *Polytechnic and Design*, 5(3), 201.
- [7] Horvat, M., Dobrinić, M., Novosel, M., & Jerčić, P. (2018, January). Assessing emotional responses induced in virtual reality using a consumer EEG headset: A preliminary report. In *41st International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2018*.
- [8] Horvat, M. (2013). Generation of multimedia stimuli based on ontological affective and semantic annotation (Doctoral dissertation, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu).
- [9] Čosić, K., Popović, S., Horvat, M., Kukolja, D., Dropuljić, B., Kostović, I., ... & Spajić, B. B. (2011). Virtual reality adaptive stimulation in stress resistance training. Proceedings RTO-MP-HFM-205 on " Mental Health and Well-Being across the Military Spectrum.
- [10] Popović, S., Horvat, M., & Čosić, K. (2008). Generator of Audio and Visual Stimuli for Psychotherapy and Psychological Training. In *Treći hrvatski simpozij o poremećajima uzrokovanim stresom s međunarodnim sudjelovanjem*.
- [11] Čosić, K., Popović, S., Horvat, M., Kukolja, D., Dropuljić, B., Kovač, B., & Fabek, I. (2012). Multimodal paradigm for mental readiness training and PTSD prevention. In *NATO Advanced Study Institute on Invisible Wounds: New Tools to Enhance PTSD Diagnosis and Treatment*.
- [12] Wiederhold, B. K., & Wiederhold, M. D. (2008). Virtual reality for posttraumatic stress disorder and stress inoculation training. *Journal of CyberTherapy & Rehabilitation*, 1(1), 23-35.
- [13] Adelman, C. B., Panza, K. E., Bartley, C. A., Bontempo, A., & Bloch, M. H. (2014). A meta-analysis of computerized cognitive-behavioral therapy for the treatment of DSM-5 anxiety disorders.
- [14] Popović, S., Horvat, M., Kukolja, D., Dropuljić, B., & Čosić, K. (2009). Stress inoculation training supported by physiology-driven adaptive virtual reality stimulation.
- [15] <https://play.google.com/store/apps/details?id=si.modula.android.instantheartrate>, dohvaćeno 10. lipnja 2018.

AUTORI · AUTHORS



Marko Horvat

Viši predavač je na Tehničkom veleučilištu u Zagrebu. Voditelj je izvanrednog preddiplomskog Stručnog studija računarstva i Laboratorija za umjetnu inteligenciju istog veleučilišta.

Diplomirao je, magistrirao i doktorirao iz znanstvenog područja tehničkih znanosti, polje računarstvo na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu, 1999., 2007. odnosno 2013. godine. Objavio je više od 60 znanstvenih i stručnih radova. Područja od osobitog profesionalnog interesa uključuju strojno učenje, dohvaćanje informacija, afektivno računarstvo, automatizirano rasuđivanje, formalno predstavljanje znanja i semantički web. Bavi se popularizacijom znanosti. Član je udruge IEEE.

Korespondenciјa

mhorvat1@tvz.hr



Denis Fodor

Završio je preddiplomski stručni studij računarstva i diplomski specijalistički studij informatike smjer računarstvo Tehničkog veleučilišta u Zagrebu. Trenutno je zaposlen u tvrtki Ars Futura d.o.o. kao inženjer za razvoj mobilnih aplikacija u operacijskom sustavu Android. Stručnjak je za razvoj programske potpore web i mobilnih aplikacija.