

Korišćenje funkcije gustine verovatnoće u postupku za prepoznavanje tipa fizičke vežbe

Nikola Cakić^{1,2}, Milica Dilparić^{1,2}, Aleksandar Žigić¹, Srđan Milosavljević¹,
Blagoje Babić^{1,2}

¹Univerzitet u Beogradu, Elektrotehnički institut "Nikola Tesla", Koste Glavinića 8A,
11000 Beograd, Srbija
nikola.cakic@ieent.org

²Univerzitet u Beogradu. Elektrotehnički fakultet, Bulevar kralja Aleksandra 73 11000
Beograd, Srbija

Kratak sadržaj: U radu je prikazan postupak za prepoznavanje fizičkih vežbi, korišćenjem samo troosnog akcelerometra pametnog telefona. Telefon se nalazi nefiksiran u džepu vežbača. Analizirane su vežbe za jačanje mišića nogu iz stojećeg položaja: čučanj, iskorak i podizanje kolena. Sve vežbe su rađene nogom u čijem džepu se nalazi senzor ubrzanja korišćenog mobilnog telefona. Da bi se testirao predloženi postupak, nasumice je odabrana vežba podizanje kolena koja se obavlja suprotnom nogom od one u čijem se džepu nalazi mobilni telefon. Filtriranje sirovih signala ubrzanja je postignuto korišćenjem Batervortovog filtra propusnika niskih učestanosti (desetog reda). Filtrirani signali svake od osa akcelerometra su opisani pomoću tri deskriptora. Nakon izračunavanja deskriptora signala, za svaki deskriptor je formirana funkcija gustine verovatnoće. Postupak za prepoznavanje vežbi se obavlja online unutar Android aplikacije pametnog telefona. Signali dve muške i dve ženske osobe su poslužili kao referenca za prepoznavanje vežbi. Uspešnost prepoznavanja je 94,22% za prepoznavanje tri vežbe, odnosno 85,33% za prepoznavanje sve četiri razmatrane vežbe.

Ključne reči: Akcelerometar, fizička vežba, deskriptor signala, funkcija gustine verovatnoće, prepoznavanje vežbi.

1. Uvod

Najrasprostranjeniji pristup u prepoznavanju aktivnosti bazira se na inercijalnim mikroelektromehaničkim MEMS sensorima. Inercijalni senzori se mogu koristiti za prepoznavanje statičkih i dinamičkih aktivnosti radi

monitoringa zdravlja [1]. Prepoznavanje aktivnosti pomoću pomenutih senzora omogućilo je i praćenje određenih rehabilitacionih programa [2].

Pored osnovne namene na polju telekomunikacija, savremeni pametni telefoni su opremljeni mnoštvom senzorskih modula. Njihova osnovna namena je softverska detekcija određenog događaja direktno uslovljenog položajem telefona u prostoru. Očitani podaci implementiranih inercijalnih senzora se pored upotrebe za upravljanje objektima unutar igrica, mogu se iskoristiti za prepoznavanje dnevnih aktivnosti ljudi [3].


Povećano korišćenje računara dovodi do fizičke neaktivnosti mlađe populacije što uzrokuje gojaznost. Gojaznost je štetna po zdravlje jer vodi ka bolestima kao što su: dijabetes, bolest srca i povišen krvni pritisak [4]. Sa druge strane, gojaznost vodi i ka mentalnim bolestima kao što su: usamljenost, anksioznost i depresija. Javne zdravstvene ustanove u razvijenim zemljama preporučuju fizičku aktivnost od po minimum pola sata dnevno, pet dana u nedelji. Međutim, manje od pola stanovništva ne ispunjava te standarde. Osnovni problem je nedostatak vremena i motivacija. U ovom radu je predstavljen postupak za prepoznavanje fizičkih aktivnosti tokom fizičkog vežbanja. Prikupljeni podaci o odrađenim vežbama mogu da doprinesu optimalnoj potrošnji resursa ljudskog organizma, kao i u planiranju rasporeda odmora i vežbanja [6].

Metode koje daju dobre rezultate prilikom prepoznavanja fizičkog vežbanja koriste stacionarne Red-Green-Blue-Depth (RGBD) kamere radi prepoznavanja slike ili stacionarne piroelektrične infracrvene (PIR) senzore [7]. Kako većina vežbača više vremena provodi u vežbanju napolju ili u prostorijama koje nemaju pomenute kamere ili senzore, osnovni problem ovih pristupa je nemobilnost.

Savremeno društvo zbog ubrzanog načina života je nezamislivo bez pametnog telefona. Mobilnost inercijalnih senzora pametnog telefona u ovom radu je iskorišćena za razvoj postupka za prepoznavanja četiri fizičke vežbe. Prepoznavanje se bazira samo na implementiranom senzoru ubrzanja unutar pametnog telefona, bez dodatnih senzora. Jedini uslov je da se telefon nalazi u džepu vežbača. Za referencu za prepoznavanje vežbi korišćene su vežbe dve muške osobe starosti 20 i 59 godina i dve ženske osobe starosti 28 i 56 godina. Preciznost predloženog postupka je testirana na muškoj osobi starosti 30 godina. Ceo softver za prepoznavanje vežbi je razvijen za rad u realnom vremenu unutar Android aplikacije. Android aplikacija je razvijena u razvojnom okruženju Android Studio. Predprocesiranje i obrada podataka se obavlja unutar pomenute aplikacije. Razvijeni softverski algoritam Android aplikacije je implementiran na smart telefon galaxy S7. Prednost predloženog rešenja, u odnosu na radove iz literature, je u broju korišćenih senzora i njihovoj nefiksiranosti. Na primer, autori [8] za prepoznavanje različitih fizičkih aktivnosti su testirali različite klasifikatore kao što su drvo odluke i veštačka neuralna mreža, ali uz pomoć tri fiksirana senzora.

2. Akvizicija podataka

Analiza fizičkih vežbi je obavljena u kordinatnom sistemu koji odgovara kordinatnom sistemu pametnog telefona. Svaka vežba se sastoji iz početnog, međupoložaja i krajnjeg položaja. Početni i krajnji položaj predstavlja stoj na nogama, dok je međupoložaj analiziranih vežbi prikazan na Slici 1.



Slika 1. Međupoložaj analiziranih vežbi: (a) čučanj; (b) podizanje desnog kolena; (c) iskorak desnom nogom; (d) podizanje levog kolena.

Da bi započeo vežbanje, vežbač pokreće Android aplikaciju i zauzima početni položaj. Nakon toga čeka dok ne čuje zvučni signal za početak vežbanja.

Pre nego što su prikupljeni signali o urađenim vežbama, na osnovu preliminarne obrade signala vežbi je zaključeno da je maksimalno vreme potrebno da se uradi jedno ponavljanje bilo koje od selektovanih vežbi 3s. Pod jednim ponavljanjem vežbe se podrazumeva da je svaki vežbač iz početnog položaja došao u međupoložaj a zatim se vratio u početni položaj. Zbog navedenog podatka o trajanju najsporije vežbe, zvučni signal se ponavlja svake 4s kako bi vežbač znao da je potrebno uraditi sledeće ponavljanje.

Nakon što su izmerene vrednosti ubrzanja prikupljene, one se prvo propuštaju kroz niskopropusni filter. Kada se filtracija podataka završi Android aplikacija računa deskriptore signala.

2.1. Očitavanja podataka akcelerometra pametnog telefona

Akcelerometar pametnog telefona generiše očitane podatke u kontinualnom modu u zavisnosti od sistemske promenljive "samplingPeriodUs", koja je definisana na takav način da se postigne najbrže moguće vreme smplovanja od 5 mS (u zavisnosti od implementiranog hardvera). Iz prethodnog sledi da je perioda odabiranja signala akcelerometara 200Hz.

2.2. Preprocesiranje izmerenih signala

Izlaz iz akcelerometra su brojne vrednosti do $78,453 \text{ m/s}^2$ sa rezolucijom od $0,002 \text{ m/s}^2$ u formatu float. Sirovi podaci se prvo propuštaju kroz niskopropusni Batervortov filter desetog reda, čija cutoff frekvencija je 20 Hz. Ova vrednost je tako odabrana iz razloga što je za dobru rezoluciju u vremenskom domenu potrebno da odnos frekvencije smplovanja i cutoff frekvencije filtra bude minimum 5, a poželjno je da bude 10. Ostali usvojeni parametri su: granična učestanost propusnog dela opsega (0,2 Hz), granična učestanost nepropusnog dela opsega (0,4 Hz), slabljenje u propusnom opsegu (3 dB), slabljenje u nepropusnom opsegu (60 dB).


Nakon filtracije signala, za svaku od tri osa akcelerometra određeni su deskriptori signala. Deskriptori signala su: maksimalna vrednost signala (max), minimalna vrednost signala (min) i standardna devijacija signala (std). Na osnovu deskriptora je opisano svako ponavljanje jedne od odabranih vežbi.

3. Prepoznavanje fizičkih vežbi

Nakon izračunavanja deskriptora, uzeta je minimalna i maksimalna vrednost svih deskriptora za sve vežbe i sve ose akcelerometra. Ceo opseg između maksimalne i minimalne vrednosti deskriptora podeljen je na celobrojne intervale - binove jedinične veličine. Binovi su popunjavani realnim vrednostima deskriptora za određenu vežbu i osu akcelerometra. Na ovaj način su formirane funkcije gustine verovatnoće.

Za određivanje dovoljnog broja ponavljanja potrebnog za formiranje funkcija gustine verovatnoće vežbači su radili proizvoljan broj ponavljanja u seriji s tim da je svako od njih uradio ukupno po 100 ponavljanja od svake vežbe. Skup za obuku klasifikatora za svakog od vežbača je podeljen na četiri podskupa sa od po 25 ponavljanja. Na ovaj način svaki od podskupova obuhvata određeni broj binova. Za najlošiji slučaj za sve vežbe zaključeno je da se nakon dva podskupa tj. 50 ponavljanja, broj binova koji opisuju određenu vežbu dalje ne povećava, odnosno gustina raspodele se stabilno estimira. Radi sigurnosti za referencu metode za prepoznavanje vežbi usvojeno je da je potrebno izvršiti po 75 ponavljanja svake od vežbi. Sekvenca merenja na osnovu kojih je vršena statistička obrada je trajala 300 ponavljanja (75 ponavljanja puta 4 referentne osobe) za svaku od analiziranih vežbi. Sekvenca na kojoj je testirano odlučivanje o vrsti detektovane fizičke vežbe je trajala 75 ponavljanja. Svaki vremenski prozor jednog ponavljanja bilo koje vežbe traje 4s.

Treba napomenuti da je za određenu osu vežbe dovoljno samo 25 ponavljanja da se raspodela ustali. U ovom slučaju se broj binova ne povećava sa povećanjem broja ponavljanja. Za pomenuti slučaj funkcija gustine raspodele verovatnoće je grupisana samo u jednom binu. Ilustracija gore navedenog se može videti na deskriptoru (maksimum) signala za primer nasumice odabranog čučnja, prikazano na Slika 2.



Slika 2. Određivanje dovoljnog broja ponavljanja potrebnog za obuku klasifikatora.
Kriterijum je prestanak povećanja broja binova

Na Slici 2 se vidi da je za Y osu dovoljan samo jedan skup od 25 merenja. Posmatrajući ose X i Z se vidi da se broj binova povećava sa povećanjem broja ponavljanja. Skup od 50 do 75 ponavljanja utiče samo na verovatnoće funkcija gustine raspodele (fgr) a ne na povećavanje broja binova koji opisuju vežbu.

Nakon definisanja potrebnog broja ponavljanja, sabrane su verovatnoće svih vežbača (korišćenih za obuku klasifikatora) za pojedinačne vežbe i ose. Formirane su ukupne verovatnoće za konkretne vežbe i ose akcelerometra. Donošenje odluke se obavlja online unutar Android aplikacije. Postupak određivanja koje ponavljanje vežbe je obavio test subjekat je sledeći:

1. Filtriranje podataka.
2. Računanje deskriptora.
3. Za svaki deskriptor se po tri ose donese odluka koja vežba ima najveću verovatnoću.
4. Donosi se odluka za pojedinačni deskriptor koja vežba je prepoznata po dve od tri ose. Treba napomenuti da se nije desilo da po svakoj od tri ose bude prepoznata različita vežba. Sa druge strane dešava se da po jednoj od tri ose nije moguće doneti odluku jer se dve vežbe prepoznaju sa istom verovatnoćom. U tom slučaju se po dve preostale ose donese odluka koja vežba je prepoznata sa većom verovatnoćom.
5. Na kraju se pomoću tri deskriptora donosi odluka tako da ako su dva od tri ili sva tri deskriptora opisana istom vežbom, doneta je odluka o kojoj se vežbi radi.

Sledećom tabelom je ilustrovan postupak za donošenje odluke koja vežba je odrađena.

Tabela 1: Postupak za prepoznavanje koja vežba je odrađena.

Vežba fgr [%]	Čučanj (Č)	Podizanje desnog kolena (PDK)	Iskorak desnom nogom (IDN)	Podizanje levog kolena (PLK)	Preliminarna odluka	Konačna odluka
min X	4,33	11	8,67	0	PDK 11	PLK
min Y	34,33	3	2,33	60	PLK 60	
min Z	12	9,33	15	11,67	IDN 15	
max X	19	2,67	11	42	PLK 42	
max Y	59,33	23	54,67	100	PLK 100	
max Z	1,67	0	1,67	3,33	PLK 3,33	
std X	15	54,67	51	49	PDK 54,67	
std Y	46,67	0,33	43,67	75,67	PLK 75,67	
std Z	23,67	9	23,67	0	Nema odluke	

Iz Tabele 1 se vidi da je preliminarna odluka za deskriptor min vežba podizanje levog kolena (PLK), jer su po sve tri ose za deskriptor min prepoznate različite vežba ali je vežba PLK prepoznata sa verovatnoćom od 60%. Što se tiče deskriptora max iz tabele se vidi da je za svaku od tri ose najveća verovatnoća da je urađena vežba PLK. Kod deskriptora std Z se vidi da po Z osi ubrzanja nije moguće doneti odluku jer su sa istom verovatnoćom prepoznate i vežba čučanj (Č) i vežba iskorak desnom nogom (IDN). Međutim, po preostale dve ose X i Y prepoznata je vežba PLK jer ima veću verovatnoću prepoznavanja nego vežba podizanje desnog kolena (PDK) po X osi. Konačno, kako se na osnovu sva tri deskriptora (min, max i std) donosi odluka da je urađena vežba PLK i to je konačna odluka.

Procenat uspešnosti prepoznavanja vežbi za slučaj sa tri i četiri vežbe je prikazan u Tabeli 2.

Tabela 2: Procenat uspešnosti klasifikacije za 75 testiranih ponavljanja.

Preciznost \ Vežbe	Prepoznavanje 4 vežbe [%]	Prepoznavanje 3 vežbe [%]
Čučanj	92	100
Podizanje desnog kolena	88	96
Iskorak desnom nogom	68	86,67
Podizanje levog kolena	93,33	/
Srednja vrednost	85,33	94,22

4. Zaključak

U ovom radu je pokazano da je moguće prepoznavanje fizičkih vežbi samo pomoću troosnog akcelerometra koji se nalazi unutar pametnog telefona. Doprinos rada je u tome što se ceo postupak od snimanja preko obrade do donošenja odluke obavlja online na smart telefonu unutar razvijene Android aplikacije.

Predložen pristup omogućava da se senzor tj. pametni telefon slobodno kreće unutar džepa korisnika. Takođe, ovaj postupak se može iskoristiti za prepoznavanje aktivnosti koje duže traju (npr. trčanje, džogiranje itd.). Stim da bi tada zbog optimalnosti resursa bilo prirodnije uvesti dodatni parametar za detektovanje početka i kraja aktivnosti, nakon čega bi se dobili adaptivni vremenskih prozori na osnovu kojih bi se formirale funkcije gustine verovatnoće.

Postojanje GSM, Bluetooth i Wifi modula unutar pametnog telefona omogućava lokalnu ili udaljenu razmenu podataka. Mogućnost komunikacije putem tekstualnih poruka omogućava pametnom telefonu online razmenu podataka o broju urađenih vežbi. Podaci o urađenim vežbama se mogu slati do personalnog trenera ili osobe nadležne za praćenje toka fizikalne terapije, koje mogu pratiti tok napretka i kreirati dalje programe na osnovu kojih će korisnik planirati dalja vežbanja.

Literatura

- [1] J. Xu, Y. Wang, M. Barrett, B. Dobkin, G. J. Pottie, and W.J. Kaiser, "Personalized Multilayer Daily Life Profiling Through Context Enabled Activity Classification and Motion Reconstruction: An Integrated System Approach," *IEEE Journal of Biomedical and Health Informatics*, 2016, 20, (1), pp. 177-188. <http://ieeexplore.ieee.org/document/6996100/>
- [2] V. Bonnet, V. Joukov, P. Fraisse, N. Ramdani, and G. Venture. "Monitoring of Hip and Knee Joint Angles Using a Single Inertial Measurement Unit

During Lower Limb Rehabilitation," *IEEE Sensors Journal*, 2016, 16, (6), pp. 1557-1564.

<http://ieeexplore.ieee.org/document/7352303/>

- [3] A. Wang G. Chen, J. Yang, S. Zhao, and C.Y. Chang, "A Comparative Study on Human Activity Recognition Using Inertial Sensors in a Smartphone," *IEEE Sensors Journal*, 2016, 16, (11), pp. 4566-4578. <http://ieeexplore.ieee.org/document/7439743/>
- [4] N. Phan, J. Ebrahimi, D. Kil, B. Piniewski, and D. Dou. "Topic-Aware Physical Activity Propagation in a Health Social Network," *IEEE Intelligent Systems*, 2016, 31, (1), pp. 5-14. <http://ieeexplore.ieee.org/document/7325206/>
- [5] I. Ar and Y.S. Akgul, "A Computerized Recognition System for the Home-Based Physiotherapy Exercises Using an RGBD Camera," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014. 22, (6), pp. 1160-1171. <http://ieeexplore.ieee.org/document/6819433/>
- [6] E. Toth-Laufer, and A. R. Varkonyi-Koczy, "A Soft Computing-Based Hierarchical Sport Activity Risk Level Calculation Model for Supporting Home Exercises," *IEEE Transactions on Instrumentation and Measurement*, 2014, 63, (6), pp. 1400-1411. <http://ieeexplore.ieee.org/document/6725620/>
- [7] Q. Guan, X. Yin, X. Guo and G. Wang, "A Novel Infrared Motion Sensing System for Compressive Classification of Physical Activity," *IEEE Sensors Journal*, 2016, 16, (8), pp. 2251-2259. <http://ieeexplore.ieee.org/document/7374660/>
- [8] M. Ermes, J. Parkka, J. Mantjarvi, I. Korhonen, "Detection of Daily Activities and Sports With Wearable Sensors in Controlled and Uncontrolled Conditions," *IEEE Transactions on Information Technology in Biomedicine*, Vol. 12, No. 1, pp. 20-26, 2008. <http://ieeexplore.ieee.org/document/4358887/>

Abstract: This paper presents a method for recognition of physical exercises, using only a triaxial accelerometer of a smartphone. The smartphone itself is free to move inside subject's pocket. Exercises for leg muscle strengthening from subject's standing position squat, right knee rise and lunge with right leg were analyzed. All exercises were performed with the accelerometric sensor of a smartphone placed in the pocket next to the leg used for exercises. In order to test the proposed recognition method, the knee rise exercise of the opposite leg with the same position of the sensor was randomly selected. Filtering of the raw accelerometric signals was carried out using Butterworth tenth-order low-pass filter. The filtered signals from each of the three axes were described using three signal descriptors. After the descriptors were calculated, a probability density function was constructed for each of the descriptors. The program that implemented the proposed recognition

method was executed online within an Android application of the smartphone. Signals from two male and two female subjects were considered as a reference for exercise recognition. The exercise recognition accuracy was 94.22% for three performed exercises, and 85.33% for all four considered exercises.

Keywords: Accelerometer, physical exercise, signal descriptor, probability density function, exercises recognition.

Using Probability Density Function in the Procedure for Recognition of the Type of Physical Exercise

Nikola Cakić, Milica Dilparić, Aleksandar Žigić, Srđan Milosavljević,
Blagoje Babić

Rad primljen u uredništvo: 02.04.2017. godine.

Rad prihvaćen: 25.09.2017. godine.

