

Klasifikacija fizi kih vežbi koriš enjem troosnog akcelerometra pametnog telefona i vešta ke neuralne mreže

NIKOLA S. CAKI , Univerzitet u Beogradu, Elektrotehni ki institut
„Nikola Tesla“, Beograd

BLAGOJE M. BABI , Univerzitet u Beogradu,
Elektrotehni ki institut „Nikola Tesla“, Beograd

MILICA B. DILPARI , Univerzitet u Beogradu,
Elektrotehni ki institut „Nikola Tesla“, Beograd

ALEKSANDAR D. ŽIGI , Univerzitet u Beogradu,
Elektrotehni ki institut „Nikola Tesla“, Beograd

SR AN B. MILOSAVLJEVI , Univerzitet u Beogradu,
Elektrotehni ki institut „Nikola Tesla“, Beograd

Stru ni rad

UDC: 550.34.038:004.032.26

DOI: 10.5937/tehnika1701082C

Rasprostranjenost pametnih telefona i njihove dovoljne ra unarske sposobnosti se mogu iskoristiti za prepoznavanje svakodnevnih fizi kih vežbi. Prikupljene informacije o obavljenim vežbama mogu se upotrebiti na polju zdravstvene informatike. Za prepoznavanje odre ene fizi ke aktivnosti potreban je ve i broj senzora ili njihovo repozicioniranje u toku vežbanja. U radu je prikazan na in za prepoznavanje vežbi samo pomo u troosnog senzora ubrzanja koji je ugra en u pametan telefon. Sam telefon se slobodno kre e u džepu korisnika. Problem broja senzora i njihovog repozicioniranja u radu je rešen filtracijom mernih signala i odabirom deskriptora signala. Analizirano je devet vežbi karakteristi nih za razli ite programe i nivoe vežbanja. Za filtriranje mernih signala koriš en je Batervortov filter propusnik niskih u estanosti desetog reda. Filtrirani signali su opisani pomo u pet deskriptora, koji su koriš eni za obu avanje vešta ke neuralne mreže (VNM). Klasifikacija tipa vežbe je obavljena pomo u VNM sa greškom od 0.7%. Pojedine vežbe se mogu obavljati samo levom ili samo desnom nogom. Ta nost klasifikacije predloženog pristupa je testirana tako što je telefon sve vreme bio u desnom džepu ak i kada je vežba obavljena levom nogom.

Klju ne re i: akcelerometar, neuralna mreža, klasifikacija, fizi ka vežba, pametni telefon

1. UVOD

Najkoriš eniji pristup u prepoznavanju aktivnosti ljudi bazira se na o itavanjima inercijalnih mikro-elektromehani kih sistema - MEMS inercijalnih senzora. MEMS senzori, na osnovu ijih mernih signala se vrši prepoznavanje aktivnosti, pripadaju grupi inercijalnih senzora kao što su akcelerometar, žiroskop i magnetometar. Koriš enje ovih senzora omogu ilo je pra enje toka oporavka fizikalne terapije [1]. Pomenuti senzori se koriste i za prepoznavanje stati kih i dinami kih aktivnosti radi monitoringa zdravlja [2, 3].

Savremeni pametni telefoni, sadrže raznovrsne

MEMS senzore ija je osnovna svrha softverska detekcija odre enog doga aja direktno uslovljenog položajem telefona u prostoru.

O itani podaci implementiranih senzora se pored osnovne namene na polju zabave (interaktivne igre) mogu iskoristiti i za klasifikaciju dnevnih aktivnosti osoba koje ih nose [4 - 6].

Nedovoljno istražena oblast u prepoznavanju aktivnosti, predstavlja prepoznavanje fizi kih aktivnosti prilikom rekreativnog ili profesionalnog fizi kog vežbanja. Fizi ka aktivnost smanjuje rizik od nastanka kardiovaskularnih bolesti, dijabetesa i osteoporoze.

Pove ano koriš enje ra unara dovodi do fizi ke neaktivnosti mla e populacije što uzrokuje gojaznost. Problem gojaznosti je štetan po zdravlje jer vodi ka bolestima kao sto su: dijabetes, bolest srca i povišen krvni pritisak. Sa druge strane, gojaznost vodi i ka mentalnim bolestima kao što su: usamljenost, anksioznost

Adresa autora: Nikola Caki , Univerzitet u Beogradu, Elektrotehni ki institut “Nikola Tesla”, Beograd, Ko-
ste Glavini a 1a, nikola.cakic@ieent.org

Rad primljen: 13.11.2016.

Rad prihva en: 22.12.2016.

i depresija. Što se ti e starije populacije javne zdravstvene ustanove preporu uju fizi ku aktivnost od po minimum pola sata dnevno, pet dana u nedelji. Me- utim, manje od pola stanovništva u razvijenim zemljama ispunjava te standarde [7 - 10].

Prepoznavanja odre enih vrsta fizi kih vežbi za- hteva ve i broj senzora ili njihovo repozicioniranje prilikom obavljanja druge vrste vežbe. U literaturi po- stoje radovi koji koriste fuziju inercijalnih senzora [4] i senzora sile koji se nalaze u obu i [11]. Postupci koji daju dobre rezultate koriste stacionarne RGB kamere radi kompjuterskog prepoznavanja slike [12] ili sta- cionarne piroelektri ne infracrvene senzore [13]. Me- utim nemobilnost sistema predstavlja problem za vežbanje na otvorenom prostoru ili vežbanje u pro- storiji koja ne poseduje kamere i ra unar.

Iz razloga što je pametni telefon postao svako- dnevnicu u savremenom društvu, u ovom radu je pre- dložen postupak za prepoznavanje devet fizi kih vežbi koriš enjem pametnog telefona. Postupak se zasniva na Android pametnom telefonu i njegovom troosnom senzoru ubrzanja, bez dodatnih senzora. Odluku o ko- jem tipu izvršene vežbe se radi donosi VNM. Jedini uslov je da se telefon nalazi u džepu korisnika, bez potrebe da se fiksira.

Prednost predloženog rešenja, u odnosu na radove iz literature, je u broju koriš enih senzora i njihovoj efiksiranosti. Na primer, autori u [3] za prepoznavanje devet razli itih fizi kih aktivnosti koriste ak trinaest razli itih fiksiranih senzora. Autori u [4] su prepozna- vali samo aktivnosti koje se obavljaju sa obe noge. Jedan od doprinosa ovog rada je i u tome što se telefon nalazi samo u desnom džepu korisnika, a mogu e je prepoznavati vežbe koje se obavljaju i levom nogom. Pogodnost pametnog telefona kao senzora je što se ne mora razvijati novi portabilni ure aj kao kod autora u [9]. Telefon kao senzor ne zahteva bilo kakvu mo- difikacija ode e ili obu e kao u radu [11]. Njegova mobilnost definitivno predstavlja prednost u odnosu na fiksirane ure aje u zatvorenom prostoru, za koje su autori [12] i [13] dokazali uspešnu primenu.

Rad je predstavljen u pet poglavlja i tri potpo- glavlja. Prvo poglavlje daje pregled postoje ih rešenja u oblasti prepoznavanja fizi kih aktivnosti. Drugo poglavlje upoznaje itaoca sa na inom prikupljanja i obrade snimljenih signala. U potpoglavlju 2.1 slike na kojima su prikazani izgledi signala akcelerometra po sve tri ose generisane su pomo u Microsoft Office Excel softverskog paketa. Slike se ne iscrtavaju ni na serveru niti na pametnom telefonu. Njihova osnovna svrha je da itaocu potvrde pogrešno klasifikovane vežbe usled sli nosti mernih signala po osama. Kori- snik ima samo informaciju koju vežbu je uradio i koliki je bio broj ponavljanja. Potpoglavlje 2.2 objašnjava

postupak filtriranja mernih signala. Poglavlje 3 i nje- govgo potpoglavlje 3.1 opisuju na koji na in je kreirana VNM. Na in obuke i testiranja, kao i kolika je us- pešnost klasifikacije. etvrto poglavlje je zaklju ak i peto literatura.


2. METODOLOGIJA PRIKUPLJANJA I OBRAD E PODATAKA NAD ODABRANIM FIZI KIM VEŽBAMA

Glavni problemi prepoznavanja fizi kih vežbi su broj i fiksiranost senzora pokreta, kao i limitiranost baterije ure aja. Kako je posedovanje mobilnog tele- fona postalo svakodnevnica u savremenom svetu nje- gove dovoljne ra unarske sposobnosti se mogu isko- ristiti na polju zdravstvene informatike [14, 15].

Radi obavljanja merenja, odabrane vežbe obavlja osoba muškog pola, prose ne visine i težine (185 cm i 80 kg, respektivno), starosti do 30 godina. Snimanje pomeraja koji nastaju prilikom vežbanja obavlja pame- tan telefon koji se nalazi nefiksiran u desnom džepu korisnika.

Analiza fizi kih aktivnosti, odnosno pomeraja u toku vežbanja se obavlja u koordinatnom sistemu koji se poklapa sa koordinatnim sistemom telefona. Ana- lizirane su dve grupe vežbi u zavisnosti od po etnog stava.

Vežbe u vertikalnom stavu: u anj, skok iz mesta, podizanje kolena i iskorak. Me upoložaji vežbi u ver- tikalnom stavu prikazani su na slika 1 (a), (b), (c), (d) respektivno.




Slika 1 - Me upoložaji za vežbe u vertikalnom stavu: (a) u anj; (b) skok iz mesta; (c) podizanje kolena; (d) iskorak.

Pošto se telefon nalazi samo u desnom džepu ko- risnika, ponavljanje odre ene vežbe sa suprotnom no- gom ne e dati ista o itavanja akcelerometra. Vežba podizanje kolena slika 1(c) i vežba iskorak slika 1(d) se obavljaju levom ili desnom nogom, s'tim da na slici 1 nisu dodate vežbe koje se obavljaju levom nogom jer je postupak identi an samo je oslonac na suprotnoj

nozi. Vežbe obavljene levom nogom, iako nisu predstavljene na slika 2, nalaze se u ukupnoj grupi vežbi koje treba klasifikovati.

Što se ti e vežbi u horizontalnom stavu analizirane su slede e vežbe: sklek, bo no dizanje noge, podizanje noge (sl. 2(a), (b), (c) respektivno).



Slika 2 - Vežbe u horizontalnom stavu: (a) sklek; (b) bo no dizanje noge; (c) podizanje noge.

Na slici 2 tamnijom bojom su prikazani po etni položaji a svetlijom me upoložaji.

Za po etak vežbanja korisnik startuje Android aplikaciju i pozicionira se u po etni položaj za željenu vežbu. U tom položaju je potrebno da miruje dok ne uje zvu ni signal za po etak vežbanja. Aplikacija detektuje da je u pitanju neki od po etnih položaja vežbi ra unaju i intenzitet vektora ubrzanja. Podaci se unutar Android aplikacije upisuju u kružni bafer veli ine etiri stotine realnih podataka tipa float. Kada se bafer napuni ra una se apsolutna greška odstupanja maksimalne i minimalne vrednosti od srednje vrednosti.

Merenjima stanja mirovanja za razli ite po etne položaje ustanovljeno je da je maksimalna greška prilikom mirovanja u toku pozicioniranja u po etnom položaju za sklek 2.33%. Na osnovu izmerenog odstupanja odabrana je duplo ve a grani na vrednost -5%. Ukoliko je odstupanje ve e od grani nog, iz kružnog bafera se obriše prvi lan a preostali lanovi se šiftuju za jedno mesto u levo.

Na mesto upražnjenog poslednjeg lana se doda pristiglo merenje i ponovo se obavlja postupak ra unanja greške. U suprotnom, ako je odstupanje manje od 5% detektovano je da se korisnik nalazi u nekom od po etnih položaja za devet mogu ih vežbi. Registrovanje po etnog položaja, propra eno je pomenutim zvu nim signalom, nakon koga korisnik zapo inje vežbanje.

Pre itanja podataka sa senzora ustanovljeno je da je vreme za koje je potrebno da se obavi jedno ponavljanje najsporije vežbe oko tri sekunde. Iz tog razloga se zvu ni signal za po etak svakog slede eg ponavljanja vežbe javlja na svake etiri sekunde.


Nakon zvu nog signala potrebno je uraditi jedno ponavljanje željene vežbe koje obuhvata kretanje iz po etnog položaja u me upoložaj, i zatim vra anje u po etni položaj.

Nad snimljenim signalima akcelerometra vrši se preprocesiranje o itanih podataka senzora koriš enjem Batervortovog filtra propusnika niskih u estanosti. Filtriranje snimljenih signala je obavljeno u softverskom paketu Matlab. Nakon filtriranja ra unaju se deskriptori signala koji se prosle uju VNM, koja se na osnovu njih obu ava. Obu ena VNM donosi odluku o tome koji tip vežbe je izvršen. VNM se nalazi na serveru kome Android aplikacija preko TCP/IP protokola šalje podatke. Aplikacija može pristupiti serveru da vidi trendove vežbanja po datumima.


2.1. O itavanje podataka senzora

O itavanje podataka akcelerometra se obavlja unutar razvijene Android aplikacije. Aplikacija se nalazi na pametnom telefonu. Za njen razvoj koriš eno je Android studio razvojno okruženje. Akcelerometar pripada grupi senzora koji o itane podatke generišu u neprekidnom modu u zavisnosti od promenljive „samplingPeriodUs“. Prosle uju i promenljivi „samplingPeriodUs“ promenljivu „SENSOR_DELAY_FASTEST“, definisano je da je semplanje podataka najbrže mogu e,. Ono zavisi od implementiranog hardvera i ovde iznosi 200 Hz. Potrebno stanje mirovanja za detekciju po etnog položaja iznosi dve sekunde.

Na slici 3 i slici 4 su predstavljeni signali za jedno ponavljanje vežbe u vertikalnom stavu. Prikazani su izgledi signala za svaku od tri ose akcelerometra (x-plava boja, y-crvena boja i z-zelena boja).




Slika 3 - Izgled sirovog signala za (a) u anj i (b) skok iz mesta. Plava boja x-osa, crvena y-osa i zelena z-osa.



Slika 4 - Izgled sirovog signala: (a) podizanje kolena, oslonac leva noga (gore), oslonac desna noga (dole), (b) iskorak, oslonac leva noga (gore), oslonac desna noga (dole). Plava boja x-osa, crvena y-osa i zelena z-osa.

Na slici 5 su predstavljeni izgledi signala određene vežbe u horizontalnom stavu. Prikazani su izgledi signala za sve tri ose akcelerometra.



Slika 5 - Izgled sirovog signala: (a) sklek, (b) bo no dizanje noge, (c) podizanje noge. Plava boja x-osa, crvena y-osa i zelena z-osa.

Kako jedno ponavljanje određene vežbe traje 4 s, sledi da se signal jednog ponavljanja željene vežbe sastoji od 800 semplova. Na slici 5(b) i slici 5(c) je obeležen početni i krajnji položaj nakon izvršenog jednog ponavljanja vežbe. Sa slike se vidi da se početni i krajnji položaji u toku vežbanja razlikuju jer telefon nije fiksiran unutar džepa već se slobodno kreće u toku vežbanja.

2.2. Preprocesiranje snimljenih signala akcelerometra

Da bi se povećala tačnost prilikom donošenja odluke VNM, nad sirovim podacima se vrši filtriranje mernih signala.

Za filtriranje sirovih signala korišćen je Butterworthov filter propusnik niskih u frekvenciji desetog reda. Oslanjaju se na karakteristike kvalitetnih osciloskopa, kod kojih se za postizanje dobre rezolucije po vremenu koriste u frekvenciji semplovanja koje su najmanje pet puta poželjnije od deset puta već od gornje granice u frekvenciji merenog signala, za granicu u frekvenciji filtra je odabrana u frekvencija koja je deset puta manja od u frekvenciji semplovanja senzora pametnog telefona. Kako je u frekvencija semplovanja senzora 200 Hz, usvojeno je da je granica u frekvenciji filtra 20 Hz. Ostali usvojeni parametri su:

- Gornja granica u frekvenciji propusnog opsega (0.2 Hz).
- Donja granica u frekvenciji nepropusnog dela opsega (0.4 Hz).
- Najveće slabljenje u propusnom opsegu (3dB)
- Najmanje slabljenje u nepropusnom opsegu (60 dB).

Na osnovu usvojenih parametara određena je minimalna red filtra, koji mora biti deset.

Nakon filtriranja signala, izvučene su informacije o pet deskriptora za svaku osu akcelerometra. Za deskriptore signala su odabrani:

- Srednja vrednost,
- Max vrednost,
- Min vrednost,
- Energija (suma kvadrata semplova),
- Standardna devijacija (kvadratni koren od varijanse dobijenih rezultata).

Pomoću pomenutih deskriptora signala opisano je jedno ponavljanje svake od ukupno devet razmatranih vežbi.

3. KLASIFIKACIJA FIZI KIH VEŽBI

Veštačka neuralna mreža (VNM) predstavlja matematički model za mašinsko učenje i uspešno se koristi za klasifikovanje signala inercijalnih senzora [16]. U softverskom paketu Matlab izvršena je obuka i testiranje VNM.

Prilikom obrade signala uočeno je da signali intenziteta ubrzanja mogu da budu slični za različite vežbe. Takođe, za neke od osa akcelerometra signali nisu karakteristični za određenu grupu vežbi kojoj pripadaju. Pomenuta problematika se javlja zbog nefiksiranosti senzora i velikog broja vežbi koje se prepoznaju u toku vežbanja. Navedeno može dovesti do greške prilikom klasifikacije VNM. Rešenje za povećanje tačnosti klasifikovanja VNM i smanjenje pogrešnih odluka usled pomeranja senzora telefona je klasifikovanje fizičkih vežbi na osnovu deskriptora signala.

Da bi se obavila klasifikacija fizičkih vežbi korišćenjem deskriptora signala, vrši se treniranje VNM. Jednom istrenirana VNM klasifikuje svako sledeće ponavljanje vežbi na osnovu njihovih deskriptora signala. Radi pronalaženja optimalnog broja deskriptora mernog signala, kao i testiranja njihovog uticaja na tačnost klasifikacije VNM, razmatrana su četiri slučaja za njihovo određivanje prilikom vežbanja:

- Deskriptori intenziteta vektora ubrzanja – ukupno pet deskriptora po signalu (skup I)
- Deskriptori jedne ose (x ose) akcelerometra – ukupno pet deskriptora po signalu (skup II)
- Deskriptori dve ose (x i y ose) akcelerometra – ukupno deset deskriptora po signalu (skup III)
- Deskriptori sve tri ose (x, y i z ose) akcelerometra – ukupno petnaest deskriptora po signalu (skup IV)

Za sva četiri pomenuta slučaja izvršeno je treniranje, validacija i testiranje VNM.

3.1. Veštačka neuralna mreža

U cilju minimizacije greške pri klasifikaciji vežbi, struktura VNM je optimizovana. To je postignuto tako što je implementirana dvoslojna feedforward VNM mreža za prepoznavanje oblika.

VNM je trenirana pomo u scaled backpropagation trening algoritma. Koeficijenti su određivani tako što se gledalo da nakon treniranja mreže, performanse validacionog i test skupa budu zadovoljavajuće. Pod terminom zadovoljavajuće podrazumeva se da nije došlo do preobnavljanja ili nedovoljnog treniranja mreže. Prvi sloj sadrži sedam a drugi pet neurona. Ulazni sloj sadrži deset a izlazni devet neurona.

etiri pomenuta skupa podataka su korišćeni za testiranje i obučavanje VNM, u cilju postizanja veštosti klasifikacije vežbi.

Ulazni vektori (devet vežbi sa po sto ponavljanja) su raspoređeni u tri skupa (obuka, validacija i test) i to:

- 70% podataka je korišćeno za obučavanje
- 15% podataka je korišćeno za validaciju
- 15% podataka je korišćeno za nezavisni test generalizacije

Konfuzionna matrica za najtačniji skup podataka (ulazni skup IV) prikazana je na slici 6.

Konfuzionna matrica

Izlazna klasa	1	2	3	4	5	6	7	8	9	
1	100 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	100 11.1%	0 0.0%	0 0.0%	2 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.0% 2.0%
3	0 0.0%	0 0.0%	100 11.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	97 10.8%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	99.0% 1.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98 10.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	3 3.0%	0 0.0%	99 11.0%	0 0.0%	0 0.0%	0 0.0%	97.1% 2.9%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 11.1%	0 0.0%	0 0.0%	100% 0.0%
8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 11.1%	0 0.0%	100% 0.0%
9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100 11.1%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	87.0% 3.0%	98.0% 2.0%	99.0% 1.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.3% 0.7%
	1	2	3	4	5	6	7	8	9	

Ciljna klasa

Slika 6 - Konfuzionna matrica za ulazni skup IV

Redovi i kolone matrice (od 1 do 9) na slici 6 predstavljaju sledeće vežbe:

- Ustanj
- Skok iz mesta
- Podizanje kolena, oslonac leva noga
- Podizanje kolena, oslonac desna noga
- Iskorak, oslonac leva noga
- Iskorak, oslonac desna noga
- Skleci
- Bočno dizanje noge
- Podizanje noge.

Dijagonalne ćelije matrice pokazuju broj slučajeva u kojima je izvršena ispravna klasifikacija, a vandiagonalne ćelije pokazuju broj slučajeva sa pogrešno izvršenom klasifikacijom.

Najbolji rezultati su dobijeni za ulazni skup podataka IV. To se moglo očekivati, pošto je korišćeno

više informacija akcelerometra. Tačnije, za ulazni skup signala IV, uspeh klasifikacije je 99.3% (sl. 6, red 10, kolona 10), te je greška klasifikacije je 0.7% što se može smatrati prihvatljivim. Kao što se može videti na slici 6, četvrta vežba je bila tri puta pogrešno klasifikovana kao šesta vežba, peta vežba je bila dva puta pogrešno klasifikovana kao druga, dok je šesta vežba samo jednom pogrešno klasifikovana kao četvrta vežba. Greška prilikom klasifikacije je značajno veća za ulazne skupove podataka I, II i III (33.9%, 44.4% i 10.8%, respektivno).

4. ZAKLJUČAK

U radu je pokazano da je moguće samo pomoću troosnog akcelerometra pametnog telefona izvršiti klasifikaciju fizičkih vežbi. Tom prilikom je za razliku od ostalih pristupa gde se koristi više i broj fiksiranih senzora, korišćen samo jedan senzor pametnog telefona koji se nalazi nefiksiran u džepu korisnika. Kako se može desiti da oblik signala po nekoj osi akcelerometra ili po intenzitetu vektora ubrzanja bude sličan za različite vežbe, postavlja se pitanje na koji način obučiti VNM da izvrši što tačniju klasifikaciju. To je urađeno uvođenjem pet deskriptora signala po svakoj osi.

Za treniranje, validaciju i testiranje VNM korišćena su četiri skupa deskriptora. Zaključeno je da je najslabija klasifikacija mreže upravo za skup I, što se objašnjava smanjenim brojem deskriptora. Pogrešna klasifikacija je rezultat sličnosti intenziteta ubrzanja vežbe jedan i vežbe osam. Ipak, zahvaljujući dobro odabranoj filtraciji signala i samim deskriptorima srednja vrednost, uspešnosti klasifikacije svih vežbi za ovaj slučaj iznosi preko 84%. Sa povećanjem broja deskriptora povećava se i tačnost klasifikovanja fizičkih vežbi, tako da se najtačnija klasifikacija dobija za slučaj kada se koriste sve tri ose i maksimalni broj od petnaest deskriptora. Za ovaj slučaj srednja vrednost uspešnosti klasifikovanja iznosi čak 99.3%. Na osnovu podataka o uspešno klasifikovanim vežbama moguće je pratiti trendove vežbanja po datumima, što omogućava sastavljanje plana i programa budućih vežbanja.

LITERATURA

- [1] Bonnet V, Joukov V, Kulić D, Fraisse P, Ramdani N, Venture G. Monitoring of Hip and Knee Joint Angles Using a Single Inertial Measurement Unit During Lower Limb Rehabilitation, *IEEE Sensors Journal*, Vol. 16, No. 6, pp. 1557-1564, 2016.
- [2] Xu JY, Wang Y, Barrett M, Dobkin B, Pottie G J, Kaiser WJ. Personalized Multilayer Daily Life Profiling Through Context Enabled Activity Classification and Motion Reconstruction: An Integrated System Approach, *IEEE Journal of Biomedical and*

- Health Informatics*, Vol. 20, No. 1, pp. 177-188, 2016.
- [3] Ermes M, Parkka J, Mantyjarvi J, Korhonen I. 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.
- [4] Wang A, Chen G, Yang J, Zhao S, Chang CY. A Comparative Study on Human Activity Recognition Using Inertial Sensors in a Smartphone, *IEEE Sensors Journal*, Vol. 16, No. 11, pp. 4566-4578, 2016.
- [5] Kang W, Han Y. SmartPDR: Smartphone-Based Pedestrian Dead Reckoning for Indoor Localization, *IEEE Sensors Journal*, Vol. 15, No. 5, pp. 2906-2916, 2015.
- [6] Liao J, Wang Z, Wan L, Cao QC, Qi H. Smart Diary: A Smartphone-based Framework for Sensing, Inferring and Logging Users' Daily Life, *IEEE Sensors Journal*, Vol. 15, No. 5, pp. 2761-2773, 2015.
- [7] Guo S, Grindle GG, Authier EL, Cooper RA, Fitzgerald SG, Kelleher A, Cooper R. Development and Qualitative Assessment of GAMECycle Exercise System, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 14, No. 1, pp. 83-90, 2006.
- [8] Maamar HR, Boukerche A, Petriu EM. 3-D Streaming Supplying Partner Protocols for Mobile Collaborative Exergaming for Health, *IEEE Transactions on Information Technology in Biomedicine*, Vol. 16, No. 6, pp. 1079-1095, 2012.
- [9] Wu MF, Chen CL, Wen CY, Hsu JY. Design of Pervasive Rehabilitation Monitoring for Chronic Obstructive Pulmonary Disease, *IEEE Sensors Journal*, Vol. 13, No. 11, pp. 4413-4422, 2013.
- [10] Phan N, Ebrahimi J, Kil D, Piniewski B, Dou D. Topic-Aware Physical Activity Propagation in a Health Social Network, *IEEE Intelligent Systems*, Vol. 31, No. 1, pp. 5-14, 2016.
- [11] Zhang Z, Poslad S. Improved Use of Foot Force Sensors and Mobile Phone GPS for Mobility Activity Recognition, *IEEE Sensors Journal*, Vol. 14, No. 12, pp. 4340-4347, 2014.
- [12] Ar I, Akgul YS. A Computerized Recognition System for the Home-Based Physiotherapy Exercises Using an RGBD Camera, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 22, No. 6, pp. 1160-1171, 2014.
- [13] Guan Q, Yin X, Guo X, Wang G. A Novel Infrared Motion Sensing System for Compressive Classification of Physical Activity, *IEEE Sensors Journal*, Vol. 16, No. 8, pp. 2251-2259, 2016.
- [14] Sardini E, Serpelloni M, Pasqui V. Wireless Wearable T-Shirt for Posture Monitoring During Rehabilitation Exercises, *IEEE Transactions on Instrumentation and Measurement*, Vol. 64, No. 2, pp. 439-448, 2015.
- [15] Zheng YL, Ding XR, Poon CCY, Lo BPL, Zhang H, Zhou XL, Yang GZ, Zhao N, Zhang YT. Unobtrusive Sensing and Wearable Devices for Health Informatics, *IEEE Transactions on Biomedical Engineering*, Vol. 61, No. 5, pp. 1538-1554, 2014.
- [16] Li G, Liu T, Yi J, Wang H, Li J, Inoue Y. The Lower Limbs Kinematics Analysis by Wearable Sensor Shoes, *IEEE Sensors Journal*, Vol. 16, No. 8, pp. 2627-2638, 2016.

SUMMARY

CLASSIFICATION OF PHYSICAL EXERCISES USING A TRIAXIAL ACCELEROMETER IN A SMARTPHONE AND AN ARTIFICIAL NEURAL NETWORK

The prevalence of smartphones and their adequate computer skills can be used for detecting everyday physical exercises. Acquired information on performed exercises can be used in the field of Health Informatics. For identification of particular physical activity a number of sensors and their repositioning during exercises are needed. This paper presents a way to classify the type of exercise using only triaxial built-in accelerometric sensor in the smartphone. The smartphone itself is free to move inside the subject pocket. The problem of using a number of sensors and their repositioning during exercise is solved by raw signal filtering and by defining a set of signal descriptors. Nine characteristic exercises have been analyzed for different programs and levels of exercise. To filter the raw accelerometer signal a low-pass 10-th order Butterworth filter is used. The filtered signals are described in terms of five descriptors which are used to train an artificial neural network (ANN). Classification of the type of exercise is performed using ANN with an error of 0.7%. Some exercises can be performed with only left or right leg. The classification accuracy of proposed approach is tested in a way that the smartphone was always in the subject's right pocket even when the exercise is performed using left leg only.

Key words: *accelerometer, neural network, classification, physical exercise, smartphone*