

Raspoznavanje i kvantifikacija tjelesne aktivnosti

Matija Varga, Tomislav Pozaić, Sara Žulj, Luka Celić i Ratko Magjarević

Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Zagreb, Unska 3

Email:

matija.varga@fer.hr

tomislav.pozaic@fer.hr

sara.zulj@fer.hr

luka.celic@fer.hr

ratko.magjarevic@fer.hr


Sažetak - Tjelesna aktivnost važan je čimbenik zdravog života pojedinca, a često je i sastavni dio rehabilitacije nakon traume ili kod nekih kroničnih bolesti. Cilj ovoga rada je razviti i ispitati sklopove za mjerenje tjelesne aktivnosti zasnovane na pokretnoj mreži osjetila i odgovarajuće algoritme za kvantificiranje rezultata mjerenja. Bežična mreža osjetila sastoji se od osjetilnih čvorova pozicioniranih na tijelu ispitanika. Uz pomoć umreženih osjetila moguće je istovremeno detektirati i druge fiziološke parametre ispitanika kao što su QRS kompleks u EKG-u, repeticija disanja i prepoznati položaj tijela te vrstu tjelesne aktivnosti. Praćenje tjelesne aktivnosti realizirano je jednim troosnim akcelerometrom, a podaci prikupljeni na osjetilnom čvoru šalju se na središnji čvor. U ovom radu razvijen je i ispitani algoritam za klasifikaciju različitih vrsta tjelovježbi. Algoritam se temelji na metodi najbližeg susjeda u n-dimenzionalnom prostoru svojstava signala. Algoritam pokazuje dobra svojstva za fizikalno različite vježbe. U radu su dani i prijedlozi rješenja za unaprjeđenje algoritma i poboljšanje metode mjerenja aktivnosti. Rezultati rada upućuju na to da je ovakav način istovremenog praćenja tjelesne aktivnosti i vitalnih parametara pogodan za primjenu pri rehabilitaciji oboljelih od dijabetesa

istraživačkim centrima već razvijaju slični sustavi za praćenje fizioloških parametara kod kroničnih bolesnika. Zbog potrebe unaprjeđivanja takvih sustava i uvođenja istih na lokalnu razinu razvijena je naša pokretna mreža osjetila i sustav za praćenje. Razvoj i uporaba opisanog sustava (od strane pacijenata kao i medicinskog osoblja) zahtijeva lokalnu stručnu podršku, prvenstveno tehnološku, a za pacijente također medicinsku i socijalne službe.

Naša preddiplomska grupa na projektu „Pokretna mreža osjetila za medicinske primjene“ spoznala je potrebu za praćenjem kvantitativnih podataka o tjelovježbi i dnevnoj tjelesnoj aktivnosti te će u ovom radu biti opisani svi principi na kojima se zasniva takvo praćenje i kvantifikacija. U drugom poglavlju opisane su metode kojima su prikupljeni i obrađeni podaci. Analiza podataka predstavljena je kroz korisničko sučelje. U trećem poglavlju prikazani su rezultati eksperimenta nakon provedene analize.

I. UVOD

Povećanje broja bolesnika s kroničnim bolestima i sve veći udio ljudi starije životne dobi povećava zahtjeve za redovitim pregledima u zdravstvenim ustanovama. Kako bi se unaprijedila kvaliteta zdravstvenog sustava, takvim je pacijentima potrebno omogućiti neprekinuto praćenje fizioloških parametara bez da se utječe na njihove uobičajene dnevne obaveze. S druge strane, rješenje koje bi dodatno opteretilo stručno osoblje u zdravstvenim ustanovama ne bi bilo prihvatljivo. U okviru razvoja pokretne mreže osjetila za neprekinuto i personalizirano praćenje zdravlja (Slika 1) razvijen je sustav koji neinvazivno mjeri osnovne fiziološke parametre (EKG, perioda udisaja i tjelesna temperatura) i kroz korisničko sučelje obavještava (alarmira) odgovornu zdravstvenu ustanovu. U ovom radu bit će opisan dio tog sustava koji raspoznaje obrasce različitih tjelesnih aktivnosti i kvantificira tjelesnu aktivnost korisnika. Kod kroničnih bolesti i starije populacije, tjelesna aktivnost je ujedno i oblik prevencije bolesti ili rehabilitacije nakon traume. Prethodnu tvrdnju potvrđuje i činjenica da se u velikim



Slika 1: Prikaz pokretne bežične mreže osjetila za medicinske primjene (prema [11]).

II. METODE I MJERENJA

A. Sklopovska podrška

Glavni čvor u mreži je središnji čvor i namijenjen je komunikaciji s krajnjim osjetilnim čvorovima. Na njemu se nalaze: mikrokontroler, microSD kartica, EKG modul, glasovno sučelje, akcelerometar i temperaturni senzori. Koristi litijske baterije CR2320, a u načinu rada praćenja, glavni čvor može raditi do 500 sati, dok korištenje punjivih litijskih baterija kakve se nalaze u većini mobitela (od 1000mAh) produžuje rad čvora do 83 dana.

Snimljeni podaci pohranjuju se na prijenosnu memoriju za vrijeme dok pokretna mreža nema kontakt prema pristupnoj točki (WAP).


Čvor kojim kontrolirano pratimo tjelovježbu (Slika 2) ima ugrađen akcelerometar tvrtke Analog Devices ADXL 345. Izlazni signal je vrijednost akceleracije u x, y i z smjeru. Osi tog koordinatnog sustava nisu vezane za koordinatni sustav Zemlje već se podudaraju s koordinatnim sustavom sa središtem u kućištu senzora. Na čvoru se koristi standard napajanja od 3,3 V, a osjetljivost akcelerometra je postavljena na 0,04 g/LSB. Frekvencija uzorkovanja je 25 Hz po kanalu.

Za komunikaciju se koristi ANT modul, dvosmjerna bežična tehnologija namijenjena za izgradnju osobnih lokalnih mreža (PAN). Mreža radi u nelicenciranom frekvencijskom području od 2,4 GHz.

B. Antropometrijski podaci

Antropometrija je metoda antropologije kojom se vrše mjerenja ljudskog tijela, njegovih dijelova i funkcionalnih sposobnosti. Mjere se udaljenosti između pojedinih točaka na tijelu (metričko mjerenje) i kutevi što ih tvore određene ravnine i linije tijela.

Za potrebe eksperimenta udaljenosti su određivane isključivo između fiksnih točaka na tijelu. U mjerenju je sudjelovalo 8 osoba od čega 6 muškaraca.




Slika 2: Fotografija osjetilnog čvora s akcelerometrom.

Tablica 1: dobivene mjere i njihova SD

Varijabla	Srednja vrijednost (cm)	Standardna devijacija (cm)
1. Visina tijela	177,0	8,15
2. Duljina nadlaktice	32,3	2,58
3. Duljina podlaktice	27,2	2,39
4. Duljina ruke	78,0	5,15
5. Duljina natkoljenice	44,0	1,41
6. Duljina potkoljenice	41,2	1,91
7. Duljina noge	92,0	1,00
8. Masa tijela (kg)	79,6	8,02


Antropometrijski podaci usko su povezani s algoritmima za klasifikaciju aktivnosti. Fizička obilježja (npr. dužine udova) utječu na amplitude signala na akcelerometru. Prilikom vrednovanja preciznosti algoritma potrebno je odrediti odstupanje antropometrijskih podataka ispitanika od podataka populacije nad kojom je razvijen algoritam (Tablica 1). Veća odstupanja antropometrijskih mjera ispitanika mogu uzrokovati pogrešne odluke prilikom klasifikacije aktivnosti.



Slika 3: Mjerene antropometrijske veličine (prema [12]).

C. Snimanje signala

Za potrebe eksperimenta, snimanje signala pojedine tjelesne aktivnosti odvijalo se u kontroliranim uvjetima na fakultetu, a signali su snimani na odabranoj grupi studenata. Način vježbanja odabran je u skladu sa savjetima stručnog medicinskog osoblja koje je preporučilo vježbanje s utezima u serijama od 12, 10 i 8 ponavljanja. U prvom dijelu mjerenja sudjelovala su 4 muška ispitanika od ukupno 8 ispitanika u populaciji. Njima je bilo dodijeljeno 8 različitih vježbi. Svaka vježba izvodila se s utezima od 2 do 5 kilograma, a ciljane grupe mišića su bili mišići ruku i nogu. Vježbe su prikazane na slici (Slika 4).




Slika 4: Grafički prikaz vježbi.

U eksperimentu je korišten jedan osjetilni čvor s akcelerometrom koji je bio pričvršćen na zapešće dominantne ruke ispitanika. Za učvršćivanje je korišten elastični zavoj. Analizom prethodnih radova [2] [3] [6] [7] [8], određeni su optimalni položaji za postavljanje čvorova:

- zapešće dominantne ruke
- gležanj dominantne noge
- kuk
- natkoljenica nedominantne noge
- nadlaktica nedominantne ruke.

Točan položaj pločice dan je slikom (Slika 5):



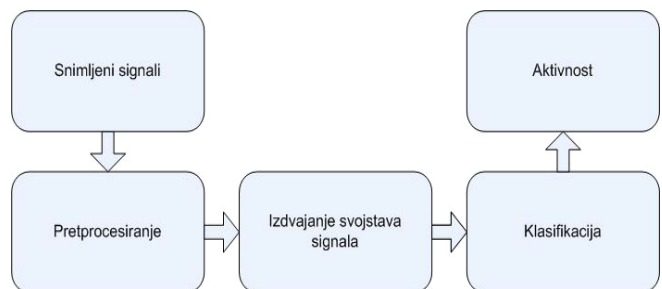
Slika 5: Položaj osjetilnog čvora

Položaj ispruženih prstiju odgovara pozitivnom smjeru osi x akcelerometra, palac odgovara pozitivnoj osi y, a os koja „izlazi“ iz dlana je pozitivna os z. Za učvršćivanje nije korišten kućište, nego je pločica s akcelerometrom bila direktno učvršćena na tijelo.

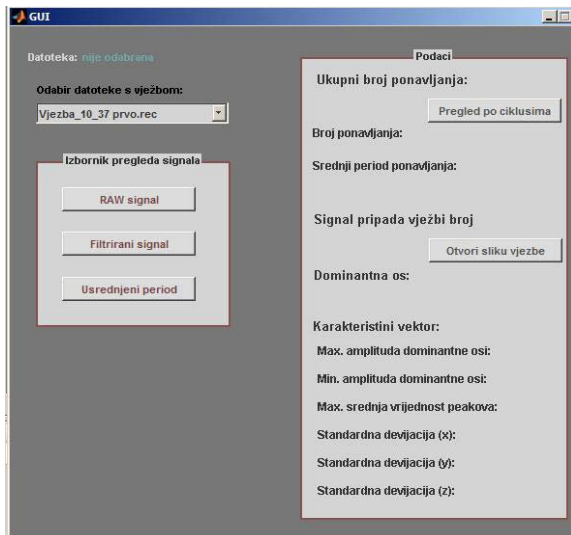
D. Metode izdvajanja svojstava signala

Nakon što su signali snimljeni, signal je potrebno prilagoditi za daljnju analizu. Filtriranje, skaliranje i slični zahvati vezani su uz fazu preprocesiranja. Iz fizikalne slike svake od vježbi možemo apriori odrediti koja će svojstva signala biti potrebno izdvojiti za daljnji proces klasifikacije. Izdvajanje svojstava signala (eng. *feature extraction*) je ključna zadaća u procesu klasifikacije tjelesne aktivnosti. Kvaliteno obrađena i izdvojena svojstva signala omogućavaju da prilikom faze klasifikacije aktivnosti možemo sa što jednostavnijim algoritmom odrediti o kojoj vrsti aktivnosti se radi. S druge strane, manje kvalitetno izdvajanje svojstava signala zahtijevat će kvalitetniji (složeniji) algoritam za klasifikaciju aktivnosti [10]. Proces klasifikacije prikazan je na slici 6 (Slika 6).

Uz pomoć alata Matlab provedena je obrada i analiza signala što uključuje preprocesiranje (filtriranje, skaliranje i sl.), izdvajanje svojstava signala te klasifikaciju aktivnosti. Sva funkcionalnost algoritma za klasifikaciju aktivnosti sadržana je u jednom grafičkom korisničkom sučelju razvijenom također u Matlabu (Slika 7).



Slika 6: Proces klasifikacije aktivnosti.

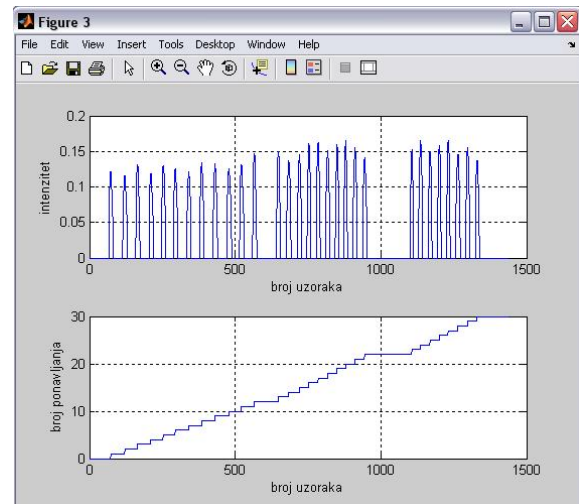


Slika 7: Grafičko sučelje u Matlabu

Budući da akcelerometar mjeri ubrzanje u x, y i z smjeru, u prvom koraku se izmjereni signal (eng. *raw signal*) sprema u tri vektora koji predstavljaju tri osi. Signal se propušta prvo kroz niskopropusni filtar, a zatim se derivira kako bi se naglasili brze promjene u signalu. Negativne vrijednosti se odbacuju (Slika 8). Na tako obrađenom signalu traži se srednja vrijednost svih lokalnih ekstrema za svaku os pojedinačno. Na temelju najmanje standardne devijacije lokalnih maksimuma određuje se os na kojoj se dominantno superponira vrijednost g (dominantna os). Na slici 8 (Slika 8) vidimo signal pripremljen za analiziranje trajanja perioda koji je prošao pretprocesiranje. To je signal koji odgovara vježbi H sa slike 4 (Slika 4). Na dominantnoj osi x vidimo 30 perioda signala čiji su lokalni maksimumi ujednačeni, a samim time im je i standardna devijacija najmanja.

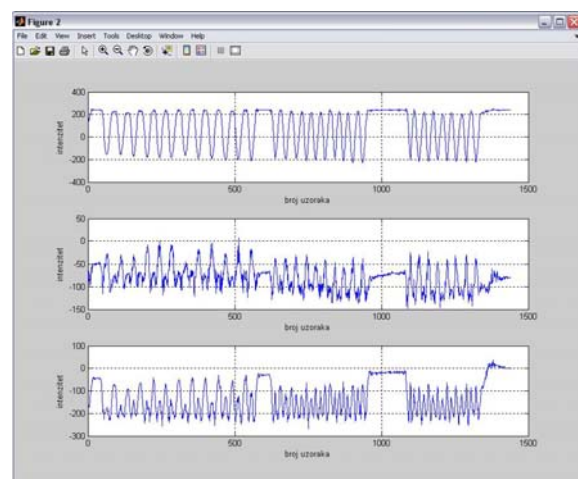
Na obrađenom signalu, detektiranjem pauze i prebrojavanjem perioda, lako je odrediti broj serija i broj ponavljanja unutar pojedine serije. Radi lakšeg pregleda tijekom vježbanja, crta se brojilo ponavljanja na vremenskoj osi (Slika 8). Praćenje trenutnog perioda daje informaciju o tome koliko se ispitanik s vremenom umara i koliko pravilno izvodi vježbu.

Algoritam određuje karakteristični vektor koji sadrži svojstva signala. Neka od svojstava su: srednji period, maksimalna i minimalna amplituda dominantne osi, srednja vrijednost dominantne osi skaliranog i filtriranog signala, standardna devijacija na dominantnoj osi i sl. Na temelju tog vektora moguće je uspoređivati svojstva signala za učenje s novim signalom i odrediti o kojoj se aktivnosti radi. Apriori analizom vježbi koje će biti snimane određena su uočljiva vremenska obilježja signala koja će poslužiti za razlikovanje između istih.



Slika 8: Prikaz dominantne osi (gore) i trajanja perioda kroz vrijeme (dolje).

Periodičnost vježbi rezultira sinusoidalnim odzivima na pojedinim osima akcelerometra. Sinusoidalni odzivi najizraženiji su na osima na koje se superponira ubrzanje sile teže. Određivanjem maksimalnih i minimalnih vrijednosti amplitude sinusoide moguće je rekonstruirati koji su kutevi što ih prebriše pojedina os akcelerometra. Osim kretanja amplituda signala možemo pronaći njihove srednje vrijednosti i periode ponavljanja. Zadnje svojstvo ne određuje neku vježbu jednoznačno, ali može poslužiti za razlikovanje između vježbi s većim i vježbi s manjim težinama utega – frekvencija s manjim utegom je često veća od one s većim utegom. Važan podatak o signalu bit će i njegova standardna devijacija. Analiza u frekvencijskoj domeni svodi se na određivanje duljine trajanja perioda jer u spektru signala postoje dvije dominantne frekvencije.




Slika 9: Filtrirani signal na sve tri osi: x, y, z.

Važno je naglasiti da prilikom izdvajanja svojstava signala smanjivanje broja istih vodi do težeg razlučivanja između većeg broja različitih aktivnosti. S druge strane, povećanje broja svojstava koje razmatramo te pretjerano ugađanje algoritma (eng. *overfitting*) za klasifikaciju može dovesti do potpune nemogućnosti prepoznavanja bilo kojeg signala osim onih na kojima je algoritam razvijen (eng. *training dataset*) [10].

E. Klasifikacijska shema

Klasifikacija uz pomoć referentnih vrijednosti signala (threshold) je najjednostavnija i najčešće se primjenjuje kao dio nekog složenijeg algoritma. Algoritam za klasifikaciju koji daje najbolje rezultate u prethodnim radovima [4][6][8] vezanima za klasifikaciju aktivnosti temelji se na konstruiranju stabla odluke (eng. *decision tree*) uz pomoć signala za učenje (eng. *training dataset*). Kada je snimljen novi signal i kada su izdvojena njegova svojstva, u svakom čvoru stabla provodi se odluka o grananju na temelju usporedbe sa svojstvima signala za učenje. Grananjem se dolazi do listova stabla koji konačno određuju koju aktivnost predstavlja novi snimljeni signal. Nedostatak ovakvog pristupa je akumulirana pogreška koja se povećava odabirom jedne od grana, tj. zanemarivanjem preostalih grana na svakoj razini stabla. Ukoliko se pokaže da je pogreška prevelika potrebno je preispitati je li svaka od grana međusobno disjunktna s ostalim granama na istoj razini.

Prije klasifikacije signala konstruirat ćemo vektor svojstava signala (eng. *feature vector*) za svaku vježbu. Svakom sljedećem signalu odredit ćemo njegov karakteristični vektor i uspoređivati ga s referentnim vektorima. Svojstva iz karakterističnog vektora moguće je lako iskoristiti za klasifikaciju uz pomoć stabala odluke ili za konstruiranje n-dimenzionalnih prostora.



Slika 10: Zelena granica – primjer preučenog algoritma za klasifikaciju


U ovom radu korišten je pristup definiranja n-dimenzionalnog prostora gdje broj n predstavlja broj dimenzija nekog signala, odnosno broj karakterističnih svojstava (eng. *feature vector*) signala. Uz pomoć signala za učenje možemo ispuniti taj prostor i odrediti granice između potprostora unutar kojih su se grupirale aktivnosti. Novi signal koji ulazi u proces klasifikacije također ćemo moći smjestiti u taj prostor i odrediti kojem potprostoru, tj. aktivnosti pripada. Funkcija koja odvaja potprostore (aktivnosti) može biti jako složena, a njezina složenost raste s brojem aktivnosti i svojstava signala. Problem kod ovakvog pristupa može nastupiti ukoliko granice između aktivnosti nije moguće odvojiti (preklapanje prostora) ili ako je granica vrlo složenog oblika.

III. REZULTATI


Nakon razvoja algoritma na temelju signala iz prve faze eksperimenta rekonstruiran je taj isti eksperiment s četiri muška ispitanika iz prve faze i jednim ženskim. Ponovljene su karakteristične vježbe s kojima je kasnije testiran algoritam za klasifikaciju. Niti jedan ispitanik nije u obje faze izvodio istu vježbu dva puta što je omogućilo kvalitetniju provjeru ispravnosti algoritma za klasifikaciju.

U prvoj fazi algoritam prepoznaje sve vježbe i točno određuje dominantu os na temelju koje broji i crta obrasce ponavljanja u signalu. Takvi rezultati su poputno očekivani, ali ne daju povratnu informaciju o kvaliteti izvedenog algoritma. Nakon testiranja algoritma u drugoj fazi ispravljani su nedostaci u algoritmu koji dovode do nepreciznog određivanja dominantne osi što ima za posljedicu loše funkcioniranje ostatka algoritma. Kod klasifikacije aktivnosti pojavljuju se problemi s prepoznavanjem fizikalno sličnih vježbi. Kod vježbi u kojima je komponenta akceleracije g konstantno usmjerena u smjeru jedne od osi akcelerometra, algoritam ima veću vjerojatnost pogrešne odluke (Slika 11). Slično, neke dvije vježbe koje imaju jednaku dominantnu os ovisne su orijentaciji preostale dvije osi i amplitudi signala na dominantnoj osi (kutu koja ta os prebriše). Ako je orijentacija preostalih osi slična, doći će do pogreške pri klasifikaciji kao na primjer u vježbi na slici 12 (Slika 12). Nameće se pitanje je li moguće samo s jednim čvorom razlikovati između takvih aktivnosti.

Dobra strana koju pokazuje algoritam je ta da pogrešne klasifikacije ostaju unutar skupine fizikalno sličnih vježbi, drugim riječima, signale vježbe na slici 11 (Slika 11) puno će teže zamijeniti sa signalima vježbe sa slike 12 (Slika 12).



Slika 11: Prikaz vježbi koje algoritam teže razlikuje.



Slika 12: Prikaz vježbi koje algoritam teže razlikuje.

IV. ZAKLJUČAK

Na temelju dobivenih rezultata možemo zaključiti da algoritam dobro prepoznaje fizikalnu sliku koju očitava signal s akcelerometra. Algoritam može razlikovati između karakterističnih skupina vježbi, a klasifikaciju zasniva na usporedbi signala za učenje (referentnih signala) i novog signala. Povećavanjem baze signala za učenje mogli bismo poboljšati referentnu vrijednost vektora svojstava svake od vježbi i time poboljšati preciznost klasifikacije. Traženjem dominantne osi na temelju standardne devijacije „šiljaka“ u signalu dobili smo kvalitetno svojstvo na kojem se temelji brojanje obrazaca ponavljanja u signalu. Dodavanjem dodatnog čvora na neka od preostalih mjesta danih u poglavlju II.C Snimanje signala, povećale bi se mogućnosti ovog sustava. Odluke pri klasifikaciji bile bi zasnovane na dvostruko većoj količini podataka, a kombiniranjem signala s dva čvora riješio bi se problem nemogućnosti razlučivanja između fizikalno sličnih aktivnosti.

U daljnjem razvoju cijelokupnog sustava za mjerenje aktivnosti planirano je neprekinuto praćenje dnevne aktivnosti ispitanika kroz period od jednog ili više dana. Prepoznavanje aktivnosti bilo bi svedeno na prepoznavanje između skupine od nekoliko temeljnih aktivnosti kao što su trčanje, hodanje, spavanje, vježbanje, detekcija pada i sl. Nakon dužeg perioda snimanja algoritam bi trebao ocijeniti aktivnost ispitanika na jednoj relativnoj skali prilagođenoj prema mogućnostima ispitanika što i je cilj jedne personalizirane mreže osjetila.

ZAHVALA

Zahvaljujemo se kolegama studentima: Kristijanu Biliću, Dominiku Džaji, Tomislavu Ivšiću i Dragi Kušiću te kolegici Andrei Poljak na njihovom doprinosu i radu na preddiplomskom projektu „Pokretna mreža osjetila za

medicinske primjene“ na Fakultetu elektrotehnike i računarstva u Zagrebu.

LITERATURA

- [1] Kavanagh JJ, Menz HB. Accelerometry: A technique for quantifying movement patterns during walking. *Gait & Posture* 2008; 28: 1-15.
- [2] Culhane KM *et al.*: Accelerometers in rehabilitation medicine for older adults. *Age and Ageing* 2005; 34: 556-560.
- [3] Kavanagh JJ.: Lower trunk motion and speed-dependence during walking. *Journal of NeuroEngineering and Rehabilitation* 2009; 6: 9.
- [4] Preece SJ *et al.*: Activity identification using body-mounted sensors – a review of classification techniques. *Physiological Measurement* 2009; 30: R1-R33.
- [5] Lyons GM *et al.*: A description of an accelerometer-based mobility monitoring technique. *Medical Engineering & Physics* 2005; 27: 497-504.
- [6] Godfrey A *et al.*: Direct measurement of human movement by accelerometry. *Medical Engineering & Physics* 2008; 30: 1364-1386.
- [7] Parkka J *et al.*: Activity classification using realistic data from wearable sensors. *IEEE Trans Inf Technol Biomed* 2006; 10(1): 119-28.
- [8] Bao L, Intille SS.: Activity recognition from user-annotated acceleration data. Massachusetts Institute of Technology. Proceedings of the 2nd International Conference on Pervasive Computing, 1-17.
- [9] Lester J *et al.*: Validated caloric expenditure estimation using a single body-worn sensor. *Computer Science and Engineering University of Washington. Ubicomb '09*, 2009.
- [10] Richard O. Duda, Peter E. Hart, David G. Stork: *Pattern Classification* (2nd edition), John Wiley & Sons, Inc 2001
- [11] Celić L., Trogrlić D., Bežični sustav za personalizirano praćenje zdravlja pacijenata, ak. g. 2009./2010., FER Sveučilište u Zagrebu
- [12] Baksa, Sarajko. Utvrđivanje individualnih biomehaničkih veličina za prosudbu težine ljudskog rada. Doktorska disertacija. FSB. Sveučilište u Zagrebu, 2007. (mentor O. Muftić).