

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 38

**ANALIZA ALGORITMA ZA AUTOMATSKO
ODREĐIVANJE PERIODA MIŠIĆNE
AKTIVNOSTI TEMELJENOG NA VALIĆNOJ
TRANSFORMACIJI**

Borna Biljan

Zagreb, lipanj 2010

Ovaj završni rad izrađen je pod stručnim vodstvom prof.dr.sc. Stanka Tonkovića, kojem se ovim putem zahvaljujem.

Također, zahvaljujem se Zrinki Potočanac, dipl.ing., za savjete i pomoć koji su mi bili od neprocjenjive vrijednosti prilikom izrade ovog rada.

Sadržaj

1. Uvod	1
2. Površinska elektromiografija.....	3
2.1. Način nastajanja elektromiografskog signala	3
2.2. Snimanje EMG signala	6
2.3. Karakteristike elektromiografskog signala	7
2.4. Postupci predobrade EMG signala.....	8
Filtriranje i ispravljanje	8
Normalizacija.....	9
Uklanjanje EKG artefakata.....	10
3. Primjena transformacija u obradi signala. Valićna transformacija	11
3.1. Fourierova transformacija.....	11
3.2. Fourierova transformacija u kratkom vremenu (STFT).....	14
3.3. Valićna (<i>wavelet</i>) transformacija	16
4. Način snimanja EMG signala koji se koriste u ovom radu	22
5. Određivanje perioda aktivnosti algoritmom zasnovanim na pragu aktivnosti	24
5.1. Algoritam Hodgesa i Buija	24
5.2. Modificirani klasični algoritam za usporedbu sa algoritmom temeljenim na valićnoj transformaciji.....	26
6. Određivanje perioda aktivnosti algoritmom temeljenim na valićnoj transformaciji...	32
6.1. Matematički model EMG signala	32
6.2. Analiza EMG signala valićnom transformacijom	34
6.3. Problem preniskog praga aktivnosti.....	41
7. Usporedba algoritama.....	43
8. Zaključak	55
9. Literatura	56
Sažetak.....	58
Summary.....	59

Privitak 1. Programski kod	60
1. Realizacija algoritma temeljenog na pragu aktivnosti.....	60
<i>classical_analysis()</i>	61
<i>apply_highpass_fir() / apply_lowpass_fir()</i>	62
<i>remove_dc()</i>	63
<i>calculate_threshold()</i>	63
<i>apply_threshold()</i>	63
2. Realizacija algoritma temeljenog na valićnoj transformaciji	64
<i>wavelet_analysis()</i>	65
<i>generate_noise()</i>	67
<i>muap()</i>	67
<i>muap_wavelet()</i>	68
3. Funkcije za postprocesiranje	69
<i>join_near_detections()</i>	69
<i>delete_short_detections()</i>	70
Privitak 2. Određivanje parametara postprocesiranja.....	71

1. Uvod

Svojim razvojem elektronika i računarstvo stječu sve važnije primjene u biologiji i medicini. Snimanje, obrada i analiza raznih električkih signala biološkog porijekla postali su važno oruđe kako za znanstvena istraživanja, tako i u svakodnevnoj medicinskoj praksi. Suvremena tehnologija olakšava napredak u istraživanju načina funkcioniranja ljudskog tijela i raznih procesa koji se u njemu odvijaju, dijagnosticiranje raznih bolesti i poremećaja, praćenja stanja pacijenata ili dobrovoljnih ispitanika i slično.

Jedan od bioelektričkih signala jest mioelektrički signal. On je posljedica procesa u stanicama mišićnog tkiva koji se odvijaju nakon pobude mišićnog tkiva iz živčanog sustava. Analiza elektromiografskih (EMG) signala daje korisne spoznaje u medicini, kineziologiji, ergonomiji itd.

Povijesno gledano, povezivanje mehaničke aktivnosti mišića i električnih signala vrlo je staro. Talijanski liječnik Luigi Galvani još je 1792. eksperimentalno dokazao da je električnom stimulacijom moguće uzrokovati kontrakciju mišića. Šest desetljeća kasnije Dubios-Raymond pokazao je da je moguće detektirati električke signale kao posljedicu voljne mišićne aktivnosti, a prvu stvarnu elektromiografsku snimku načinio je Étienne-Jules Marey 1890. godine. Od njega potječe i naziv „elektromiografija“. Klinička primjena EMG signala u liječenju raznih poremećaja počela je 1960-ih godina radom Hardycka i suradnika.

Elektromiografija je počela kao invazivna tehnika – mioelektrički signali su se snimali umetanjem elektroda u mišiće. Za primjene u medicini, i danas se djelomično koriste invazivne tehnike u elektromiografiji. Osim neugode za ispitanike, takva metoda u velikoj mjeri ograničava kretanje ispitanika, koje je često upravo predmet proučavanja. Razvojem sve boljih i sve manjih instrumentacijskih pojačala, 1980-ih godina počinje se razvijati i površinska elektromiografija, koja je kao neinvazivna tehnika pogodnija za primjenu sa ispitanicima i pacijentima.

Temporalni parametri mioelektričkih signala su se u pravilu analizirali „ručno“ – određivanje perioda aktivnosti mišića analizom signala bi provodio ekspert. Međutim, zbog ubrzanja postupka analize, mogućnosti rada u stvarnom vremenu i smanjenja troškova, pokušavaju se razviti postupci za automatsku analizu tih signala. Obrada i analiza signala uglavnom se provodi digitalno, nad uzorkovanim signalima.

Neki od parametara koji se analizom pokušavaju utvrditi u EMG signalima su početak i trajanje mišićnih aktivnosti. Obzirom na stohastičku prirodu i nedostatak jasno uočljivih karakterističnih obilježja EMG signala, različite razine šuma i smetnji u snimkama signala, te drugih faktora koji utječu na kvalitetu snimanja, određivanje tih parametara često nije jednostavan zadatak niti za školovanog istraživača, a kamoli za računalni algoritam. Stoga ne postoji univerzalni konsenzus među stručnjacima o tome koji je algoritam najbolji za automatsko određivanje početka i trajanja mišićne aktivnosti iz EMG signala, te se još uvijek istražuju razne mogućnosti u tom polju.

U ovom diplomskom radu slijedi kratak opis načina nastanka i svojstava elektromiografskog signala, te opis i implementacija određivanja perioda mišićne aktivnosti pomoću jedne relativno nove metode obrade signala – valićne (*wavelet*) transformacije. Osim te metode, u radu će se implementirati i stariji algoritam za određivanje perioda aktivnosti usporedbom amplitude signala sa pragom aktivnosti, te će se usporediti njegova učinkovitost sa novijim algoritmom.

2. Površinska elektromiografija


Površinska elektromiografija je eksperimentalna tehnika koja se bavi proučavanjem načina nastanka, snimanjem i analiziranjem mioelektričnih signala. Mioelektrični signali nastaju promjenama fiziološkog stanja membrana u mišićima. Postoje dva osnovna smjera istraživanja:

- Analiza reakcije mišića na umjetno generiranu vanjsku električku pobudu (neurološka elektromiografija)
- Analiza neuromuskulatorne aktivnosti prilikom mirovanja u određenom položaju ili prilikom obavljanja određenih pokreta, obavljanja posla i sl. (kineziološka elektromiografija)

Osim za fiziološka i biomehanička istraživanja, kineziološka je elektromiografija korisna tehnika za analizu i procjenu ostvarenog napretka u fizioterapiji i rehabilitaciji pacijenata, prilikom treninga sportaša i slično. Snimanje elektromiografskih signala omogućuje uvid u stanja pojedinih mišića te mjerenje njihovih performansi, što pomaže kod određivanja optimalnih uvjeta vježbanja i objektivnu mjeru ostvarenog napretka za sportaše, odnosno utječe na odluke o načinu liječenja i terapije u medicini.

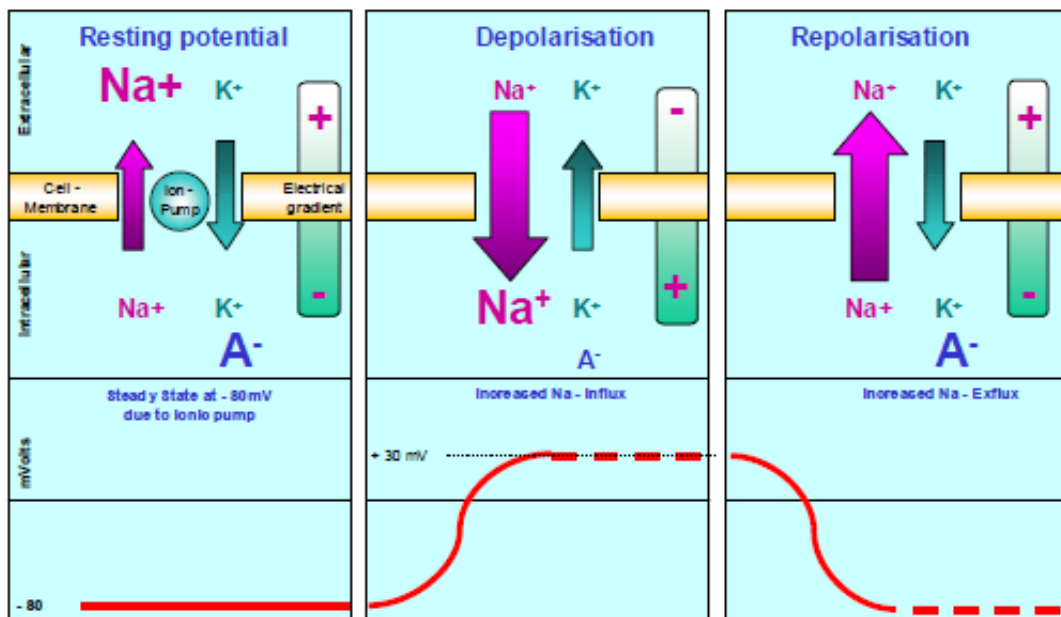
2.1. Način nastajanja elektromiografskog signala

Električni signali za aktivaciju mišića iz živčanog sustava dolaze do mišića preko stanica koje se zovu *motoneuroni* (slika 2.1). Električni impuls uzrokuje fiziološke promjene u mišićnom vlaknu i njegovo stezanje (Konrad, 2005).



Slika 2.1. Veza živčanog sustava i mišića preko motoneutrone (Konrad, 2005)

Stanice mišića imaju polupropusnu membranu. Fiziološki mehanizmi („ionska pumpa“) potiču prolazak iona kroz tu membranu, te se pojavljuje razlika potencijala između unutrašnjosti i vanjštine stanice. Ta razlika iznosi oko - 80 do - 90 mV kad je mišić u mirovanju i zove se potencijal mirovanja (*resting potential*). Aktivacija mišića započinje dolaskom električkog signala živčanim vlaknima do motoneutrone. Po dolasku električkog signala, motoneuron počinje izlučivati transmitere na svom kraju koji je vezan sa mišićnim vlaknima. Transmiteri nakratko mijenjaju svojstva membrane mišićnih stanica, čime Na^+ ioni počinju ulaziti u stanicu te uzrokuju promjenu potencijala na membrani stanice. Ovaj se proces naziva *depolarizacija*, a nastali potencijal *akcijski potencijal*. Potencijal mirovanja ponovno se uspostavlja djelovanjem ionske pumpe u procesu koji se zove *repolarizacija* (slika 2.2).



Slika 2.2. Procesi depolarizacije i repolarizacije stanične membrane te pojava akcijskog potencijala (Konrad, 2005)

Međutim, akcijski potencijal ne ostaje ograničen na lokalno područje oko spoja motoneurona i mišićnog vlakna, već se nastavlja širiti mišićnim vlaknom. Širenje tog potencijala potiče ulazak iona kalcija u mišićne stanice, što kroz niz povezanih kemijskih procesa naposljetku dovodi do stezanja mišićnog vlakna.

Mjerenje elektromiografskog signala zapravo je mjerenje akcijskih potencijala, to jest procesa depolarizacije i repolarizacije membrana mišićnih stanica. EMG signal tipično se mjeri diferencijalnim pojačalom, tj. koristeći dvije elektrode. Mišić se sastoji od mnogo tzv. motoričkih jedinica – cjelina koje obuhvaćaju motoneuron, grane njegovog aksona, te mišićna vlakna s kojima je povezan i na koja može djelovati električkim signalom. Signal kojeg daje jedna motorička jedinica naziva se *motor unit action potential* (MUAP) (Konrad, 2005). MUAP signali pojedinih motoričkih jedinica zbrajaju se i zajedno čine signal koji mjeri diferencijalno pojačalo. Važna osobina tog signala jest da je to bipolarni signal sa srednjom vrijednošću jednakom nuli.

Da bi postigli željeni motorički rezultat, upravljački mehanizmi u živčanom sustavu određuju koje motoričke jedinice žele aktivirati, a snagu koju žele dobiti iz pojedinih mišića reguliraju frekvencijom stvaranja novih MUAP-a. Međutim, ljudsko tkivo na električne signale djeluje kao niskopropusni filter, te stoga EMG signal mjereno na površini ne odražava točne frekvencije i amplitude izvornog signala.

2.2. Snimanje EMG signala

Na kvalitetu snimanja utječu razni faktori, kao što su razina električkih smetnji u prostoru u kojem se obavlja snimanje, preslušavanje EMG signala između različitih mišića, promjena karakteristika tkiva uslijed promjene temperature i fizioloških promjena, pomaci elektroda te unutarnje karakteristike elektroda i pojačala koja se koriste.

Preslušavanje EMG signala sa mišića koji su susjedni mišiću koji se promatra može biti značajno, te iznositi 10% - 15% amplitude signala koji dolazi sa promatranog mišića. Znatnu smetnju može predstavljati i EKG signal, pogotovo kad se EMG mjerenja vrše na gornjem dijelu trupa i ramenima.

Kao što je već spomenuto, ljudsko tkivo, a posebno masno tkivo, djeluje kao niskopropusni filter i prigušuje EMG signal na putu od mišićnog vlakna do kože. Različiti fiziološki parametri tkiva i biološka varijabilnost čine amplitudu EMG signala vrlo promjenjivom od ispitanika do ispitanika, između pojedinih mjerenja te između različitih mišića na istom ispitaniku. Stoga se apsolutni iznos amplitude izmjerenog signala ne može koristiti direktno za usporedbe različitih ispitanika.

Za kvalitetno snimanje EMG signala potrebna je i posebna priprema kože – čišćenje kože od nečistoća, uklanjanje mrtvih stanica sa površine kože abrazivnim sredstvima i slično. Cilj tih postupaka je smanjiti impedanciju kože i osigurati dobro prijanjanje elektroda. Idealno, impedancija kože trebala bi iznositi do 5 k Ω , no, ovisno o zahtjevima mjerenja, prihvatljive su impedancije do 30 k Ω .


Pojačala koja se koriste za snimanje EMG signala trebaju biti diferencijalna pojačala sa vrlo visokim faktorom potiskivanja (instrumentacijska pojačala), te ulaznom impedancijom od 1 – 10 M Ω u radnom području od 10 Hz do 500 Hz. Kvaliteta elektroda također je vrlo važna. Moguća je upotreba aktivnih elektroda, tj. elektroda koje imaju ugrađena predpojačala u sebi.

Nakon pojačavanja u pojačalu, signal se tipično pretvara u digitalni oblik analogno-digitalnim (A/D) konverterom. Za većinu primjena vezanih uz EMG, dovoljno je koristiti EMG pojačalo sa 12-bitnom rezolucijom. Također, obzirom na to da frekvencija EMG signala seže do 500 Hz, potrebno je koristiti frekvenciju uzorkovanja od najmanje 1000 Hz.


2.3. Karakteristike elektromiografskog signala

EMG signal koji nije prethodno podvrgnut nikakvoj obradi, osim pojasno – propusnog filtriranja, naziva se izvorni EMG signal (slika 2.3a). Prilikom mišićne aktivnosti, na površini kože mjeri se signal amplitude do 5000 μV , a frekvencije od 6 Hz do 500 Hz, s time da najviše energije sadrže komponente na frekvencijama od 20 Hz do 160 Hz. Najistaknutija frekvencijska komponenta obično je u području od 50 Hz - 80 Hz. Nakon 80 Hz, snaga postepeno pada i oko 250 Hz dosegne razine bliske 0 (slika 2.3b). Istaknuti „šiljci“ u spektru snage izvan navedenih frekvencija najčešće su posljedica vanjskih smetnji. Problem, međutim, predstavlja činjenica da smetnje koje potječu od gradske mreže imaju osnovne harmonike na frekvenciji od 50 Hz (u Europi), odnosno 60 Hz (u Americi).

EMG signal je slučajne prirode i nema istaknute karakteristike koje bi se ponavljale tokom više različitih aktivnosti niti prilikom ponavljanja iste aktivnosti više puta. Razlog tome je taj što se broj i frekvencija aktivacije mišićnih vlakana koja se koriste prilikom svake aktivnosti mijenja.



Slika 2.3a. Neobrađeni EMG signal (Konrad, 2005)



Slika 2.3b. Spektar snage EMG signala (Konrad, 2005)

Kad nema mišićne aktivnosti, mjereni signal se svodi na osnovnu liniju (tzv. EMG *baseline*), koja je u većoj ili manjoj mjeri zašumljena. Kvaliteta EMG *baseline*-a je važan pokazatelj ukupne kvalitete snimanja EMG signala, obzirom da se iz nje može procijeniti razina smetnji i šuma prisutnih prilikom snimanja. Maksimalna amplituda smetnji i šuma ne bi smjela prelaziti 15 μV ; usrednjena apsolutna vrijednost smetnji i šuma bi trebala iznositi do 3.5 μV .

Osnovna linija mora odgovarati iznosu od 0 μV , to jest ne smije postojati pomak (*offset*) prilikom mjerenja. Obzirom da je srednja vrijednost EMG signala jednaka nuli, i srednja vrijednost cijelog signala mora biti jednaka nuli. Stoga, ukoliko u mjerenju postoji pomak osnovne linije, potrebno ga je kompenzirati oduzimanjem srednje vrijednosti od izmjerenog signala. U protivnom, zaključci koji se zasnivaju na amplitudi signala neće biti valjani.

2.4. Postupci predobrade EMG signala

Filtriranje i ispravljanje

Izvorni EMG signal u sebi sadrži brojne informacije, a njegov slučajan oblik i širok raspon frekvencija uvjetuju nemogućnost sofisticiranije predobrade bez potencijalnog gubitka važnih informacija. Stoga se za znanstvene primjene ne preporuča korištenje bilo kakvih hardverskih filtara, osim pojasno-propusnog filtra koji propušta frekvencije od 10 do 500 Hz (Konrad, 2005).

Nakon analogno-digitalne pretvorbe, prvi je korak najčešće ispravljanje signala, čime se sve negativne amplitude pretvaraju u pozitivne. To omogućuje korištenje parametara kao što su srednja vrijednost signala za analizu (obzirom da je srednja vrijednost izvornog EMG-a jednaka nuli).

Normalizacija

Zbog velikih razlika u uvjetima snimanja između raznih mišića i raznih ispitanika, amplituda izmjerenog EMG signala također znatno varira od mjerenja do mjerenja. Posljedica toga jest ta da se snimke EMG signala sa raznih mišića i između raznih ispitanika ne mogu direktno uspoređivati po amplitudi. Stoga su razvijeni postupci normalizacije, kojima se signali nastoje učiniti usporedivima po amplitudi, a ponekad i po trajanju.

Jedan od postupaka normalizacije signala jest normalizacija prema maksimalnoj voljnoj kontrakciji mišića (*maximum voluntary contraction, MVC*). Nakon početnog zagrijavanja, od ispitanika se traži da postupno povećavaju silu koju daje neki mišić dok je statički opterećen (npr. pritiskanje podloge i sl.) do maksimalne sile kojom mogu djelovati. Povećavanje sile treba trajati od 3 do 5 sekundi, potom ispitanik treba pokušati zadržati maksimalnu silu tokom 3 sekunde te na kraju ponovno postupno opustiti mišić tokom 3 sekunde. Postupak treba ponoviti barem jednom, a stanika između perioda aktivnosti treba biti duga 30-60 sekundi. Na EMG snimci takve aktivnosti tada se mogu razlučiti periodi aktivnosti i neaktivnosti. Normalizacija se potom provodi tako da se odabere period aktivnost sa najvišom prosječnom amplitudom izmjerenog EMG signala, te se amplitude EMG signala snimljenih na tom mišiću i ispitaniku prilikom ostalih aktivnosti prikazuju kao postotak izmjerene maksimalne amplitude (Konrad, 2005).

Iskazivanjem izmjerenih amplituda EMG signala u postocima maksimalne amplitude omogućuju se usporedbe između raznih ispitanika, koje nisu moguće korištenjem apsolutnih iznosa amplitude EMG signala. Osim toga, usporedba razine mišićne aktivnosti pri pojedinim radnjama sa maksimalnom aktivnosti koju mišić može dati pruža korisne informacije u terapiji, prilikom vježbanja i slično.

Nedostatak opisanog postupka normalizacije jest taj što se može koristiti samo sa zdravim ispitanicima. Nadalje, greške u postupku mjerenja MVC amplitude EMG signala čine i sva kasnija mjerenja nevjerodostojnima. Osim toga, ispitanici koji nisu profesionalni sportaši i nisu navikli na takva ispitivanja, najčešće nisu sigurni kolika je maksimalna sila koju

njihovi mišići mogu dati. Stoga su razvijeni i drugi postupci normalizacije EMG signala – na primjer, normalizacija koristeći srednju vrijednost amplitude ispravljenog signala, ili koristeći vršnu vrijednost amplitude izmjerene signala (umjesto maksimalne prosječne vrijednosti tokom perioda aktivnosti).

Uklanjanje EKG artefakata

Kao što je već spomenuto, potencijalan problem prilikom snimanja EMG signala su drugi bioelektrički signali, osobito EKG, koji bivaju detektirani zajedno sa EMG signalom. Problem je naročito izražen kod snimanja EMG signala na gornjem dijelu tijela, zbog blizine srca.

Obzirom da se spektar EKG signala poklapa s nižim frekvencijama u spektru EMG signala, nije ga moguće odstraniti klasičnim filtriranjem. Međutim, razvijeni su algoritmi koji koriste tzv. adaptivne filtre i koji mogu ukloniti EKG artefakte iz signala bez znatnog utjecaja na EMG signal. Takvi algoritmi iskorištavaju činjenicu da EKG ima vrlo karakterističan oblik, te ga na temelju oblika pronalaze u EMG signalu i iz njega uklanjaju.

3. Primjena transformacija u obradi signala. Valićna transformacija

Uz linearno i nelinearno filtriranje, klasični postupci obrade i analize signala uključuju još i transformacije. Transformacijom se signal pretvara iz prikaza u jednoj domeni (tipično, vremenskoj domeni, u kojoj je signal prikazan ovisnošću njegove amplitude o vremenu) u prikaz u drugoj domeni (na primjer, frekvencijskoj domeni, gdje je signal prikazan kao suma osnovnih signala različitih frekvencija i amplitude).

3.1. Fourierova transformacija

Najstarija i najpoznatija transformacija koja prevodi signale iz vremenske u frekvencijsku domenu i obrnuto jest *Fourierova transformacija*, nazvana prema francuskom matematičaru i fizičaru Jeanu Baptisteu Josephu Fourieru (1768 - 1830), koji ju je otkrio.

Uobičajena definicija Fourierove transformacije jest (Babić, 1996):

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt \quad (3.1)$$

Pri čemu je $x(t)$ funkcija koja se transformira. Strogo matematički gledano, nije moguće izračunati Fourierovu transformaciju proizvoljne funkcije; no pokazuje se da je Fourierova transformacija izračunljiva za sve signale od praktičnog interesa¹.

Iz poznate Fourierove transformacije nekog signala, moguće je izračunati i vremenski prikaz tog signala (tj., iz poznavanja Fourierove transformacije funkcije moguće je izračunati i polaznu funkciju):

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega)e^{j\omega t} d\omega \quad (3.2)$$

Takva transformacija naziva se *inverzna Fourierova transformacija*.

Inverzna Fourierova transformacija daje i temelj za fizikalno tumačenje Fourierove transformacije. Koristeći svojstvo kompleksne eksponencijalne funkcije

$$e^{jx} = \cos(x) + j \sin(x)$$

¹ U praksi je analitički oblik signala $x(t)$ najčešće nepoznat, te stoga nije niti moguće izračunati stvarnu Fourierovu transformaciju prema definiciji, već se računa njena numerička aproksimacija.

Inverznu Fourierovu transformaciju možemo zapisati kao

$$x(t) = \frac{1}{2\pi} \left(\int_{-\infty}^{\infty} X(\omega) \cos(\omega t) d\omega + j \int_{-\infty}^{\infty} X(\omega) \sin(\omega t) d\omega \right) \quad (3.3)$$

Integral je, po svojoj definiciji, granična vrijednost sume, te su gornji integrali zapravo granične vrijednosti suma koje čine pribrojnici oblika $X(\omega)\cos(\omega t)$ i $X(\omega)\sin(\omega t)$. Fizikalno, to znači da se realni signal može prikazati kao suma (beskonačno mnogo) signala sinusa i kosinusa različitih frekvencija, a čija je amplituda na frekvenciji ω jednaka $X(\omega)$.

Funkcija nastala Fourierovom transformacijom, $X(\omega)$, općenito se sastoji od realnog i imaginarnog dijela. Dakle, možemo je uvijek prikazati kao

$$X(\omega) = |X(\omega)|e^{j \arg(X(\omega))} \quad (3.4)$$

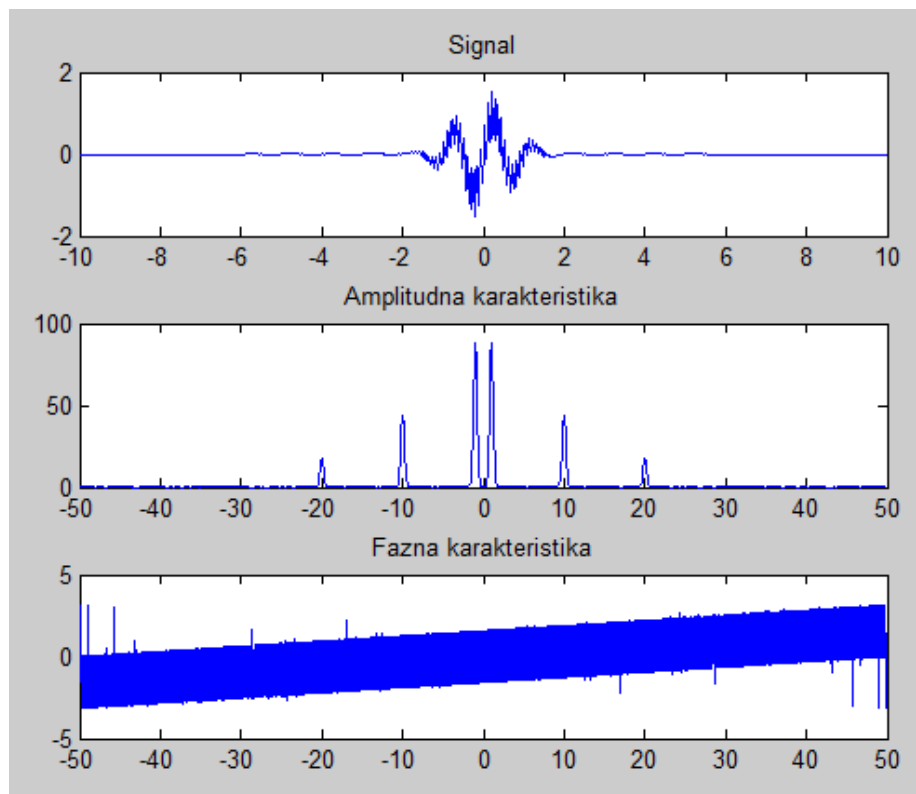
Apsolutna vrijednost od $e^{j \arg(X(\omega))}$ je uvijek jednaka 1; uspoređujući (3.4) sa (3.3) vidimo da je vrijednost frekvencijske komponente nekog signala $x(t)$ na frekvenciji ω proporcionalna sa apsolutnom vrijednošću njegove Fourierove transformacije na toj frekvenciji, $|X(\omega)|$. Stoga se $|X(\omega)|$ naziva *amplitudno-frekvencijskom* karakteristikom nekog signala $x(t)$; $\arg(X(\omega))$ naziva se *fazno-frekvencijskom* karakteristikom. Svaki realni signal jednoznačno je određen sa ove dvije karakteristike, to jest, s time kolike su amplitude njegovih frekvencijskih komponenata na pojedinim frekvencijama i kako su te komponente međusobno fazno pomaknute.

Na primjer, uzmimo signal

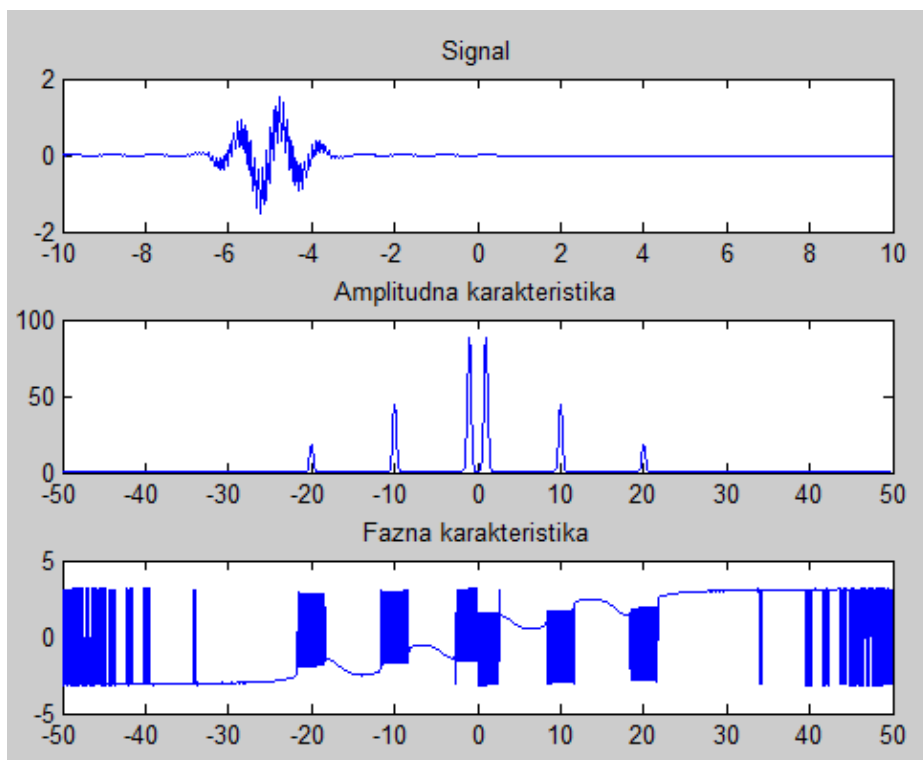
$$x(t) = (\sin(2\pi t) + 0.5 \sin(20\pi t) + 0.2 \sin(40\pi t))e^{-t^2} \quad (3.5)$$

Na slici 1 prikazan je grafički prikaz tog signala, te njegove amplitudno-frekvencijske i fazno-frekvencijske karakteristike. Na amplitudno-frekvencijskoj karakteristici jasno se vide komponente signala na 1 Hz, 10 Hz i 20 Hz, koje odgovaraju frekvencijama pribrojnika koje čine gornju funkciju. I bez poznavanja analitičkog izraza kojim je zadan analizirani signal, promatrajući informacije dobivene Fourierovom transformacijom mogli bi reći da signal ima bitne komponente na frekvencijama 1 Hz, 10 Hz i 20 Hz. Iz tog razloga, Fourierova transformacija je moćno oruđe u obradi i analizi signala.

Signal (3.5) ima izraženu amplitudu samo u vremenu oko 0 sekundi, to jest, glavninu energije nosi samo u kraćem periodu vremena. Što ako signal pomaknemo u vremenu? Fourierova transformacija tada pokazuje razliku u fazno-frekvencijskoj karakteristici signala, no amplitudno-frekvencijska karakteristika ostaje ista – signal i dalje ima iste frekvencijske komponente, ali su one drukčije raspoređene u vremenu. Na žalost, Fourierova transformacija ne daje jasnu informaciju o tome kako su pojedine frekvencijske komponente signala raspoređene u vremenu. Problem se vidi usporedbom slike 3.1 sa slikom 3.2.



Slika 3.1. Signal i njegova amplitudno-frekvencijska i fazno-frekvencijska karakteristika



Slika 3.2. Amplitudne i fazne karakteristike pomaknutog signala

Kako, dakle, otkriti koje su frekvencijske komponente prisutne u kojem dijelu signala?

3.2. Fourierova transformacija u kratkom vremenu (STFT)

Jedna ideja je da umjesto računanja Fourierove transformacije cijeloga signala, originalni signal podijelimo na odsječke, te računamo Fourierovu transformaciju za svaki odsječak posebno. Na taj način je moguće barem djelomično otkriti koje su frekvencijske komponente prisutne u kojem vremenskom razdoblju.

Takva modifikacija originalne Fourierove transformacije naziva se *Short-time Fourier transform (STFT)*, tj. Fourierova transformacija u kratkom vremenu. Matematički se može zapisati kao (Polikar, 1999)

$$X(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (3.6)$$

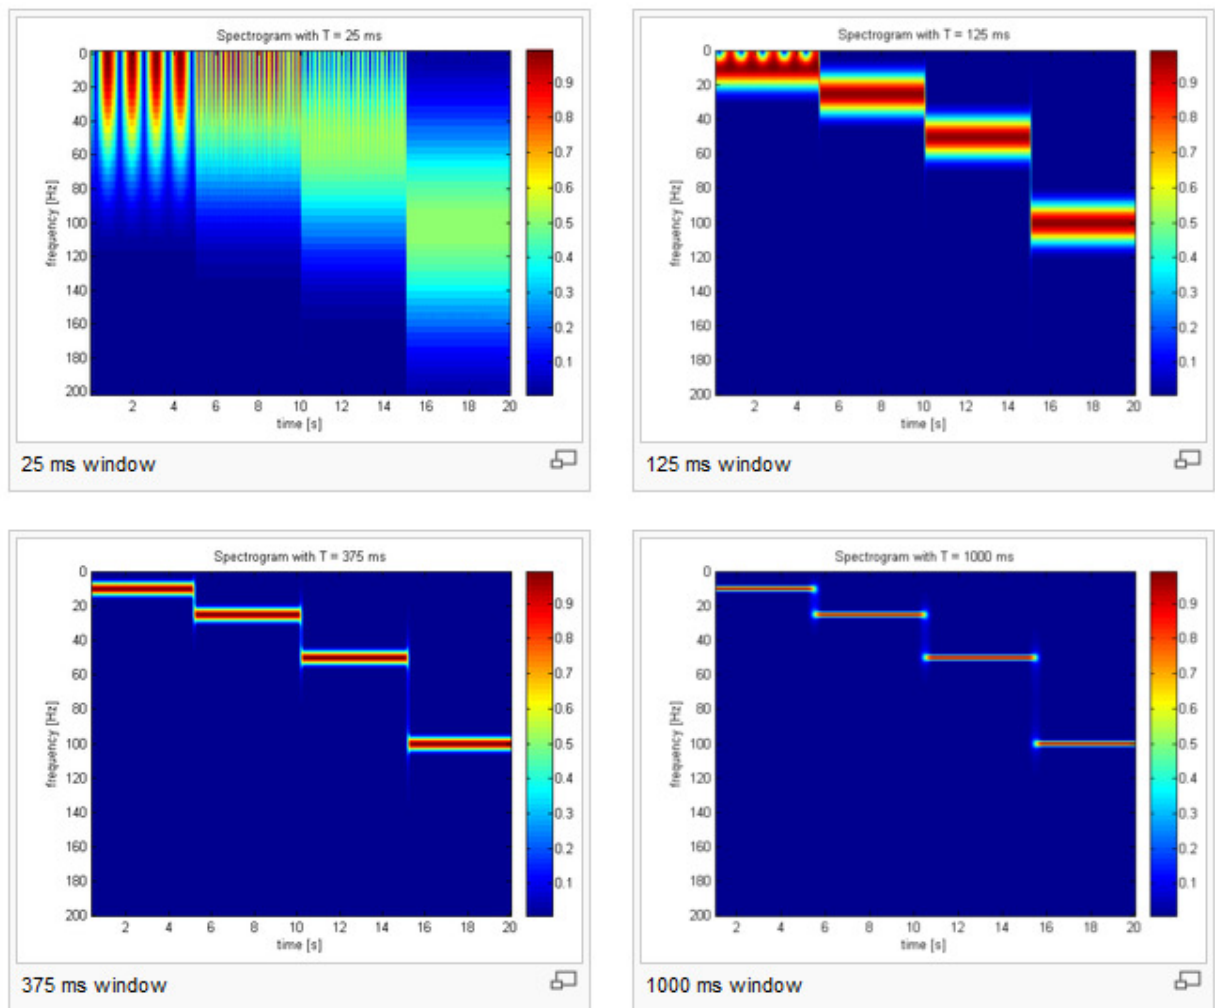
Dakle, odsječke iz originalnog signala uzimamo tako što originalni signal množimo sa „prozorom“ $w(t)$. Prozor svodi većinu originalnog signala na vrijednost 0, osim u određenom vremenskom periodu. „Pomičući“ prozor po signalu (tj. mijenjajući vrijednost pomaka τ), dobivamo odsječke signala oko različitih vremenskih trenutaka. Računajući Fourierove transformacije tih odsječaka, vidimo u kojem su vremenskim razdobljima prisutne koje frekvencijske komponente.

STFT nije više samo funkcija frekvencije, kao što je to slučaj sa Fourierovom transformacijom, već i vremenskog pomaka prozora, τ . Grafički prikaz STFT-a stoga je ploha u prostoru.

Ostaje pitanje odabira funkcije-prozora. Postoji nekoliko dobro poznatih oblika funkcija-prozora, npr. pravokutni prozor, Hammingov prozor, Gaussov prozor, itd. Kolika treba biti širina prozora? Pretpostavimo da želimo što točnije odrediti trenutak u kojem se javljaju određene frekvencijske komponente (npr. više frekvencije). To znači da moramo odabrati uski prozor, jer što je prozor vremenski uži, to bolje znamo vrijeme u kojem se javlja određena frekvencijska komponenta. Nažalost, svojstvo je Fourierove transformacije da sužavanje vremenskog trajanja neke funkcije proširuje njen frekvencijski spektar. Frekvencijske komponente više nisu lokalizirane u spektru, već se „razmazuju“ preko šireg frekvencijskog područja. Da bismo preciznije odredili koje su točno frekvencijske komponente prisutne u originalnom signalu, nužno moramo uzeti širi prozor, no time gubimo vremensku određenost.

Ta je problematika ilustrirana slikom 3. Originalni signal je signal koji se sastoji od četiri odsječka, svaki trajanja 5 sekundi. U prvom odsječku, signal je sinusoida frekvencije 10 Hz; u drugom odsječku je to sinusoida frekvencije 25 Hz, u trećem 50 Hz a u četvrtom 100 Hz. Kod transformacije kratkim prozorom od 25 ms jasno se vidi trenutak u kojem dolazi do promjene frekvencije, no nejasno je o kojoj je točno frekvenciji riječ u pojedinim intervalima. Kod dužih prozora je frekvencija sve preciznije i preciznije određena, no sada se gubi točan vremenski trenutak prijelaza između različitih frekvencija.

Fiksna širina prozora i problemi sa rezolucijom koji nastaju zbog toga osnovni su nedostatak STFT. Taj je nedostatak motivirao i razvoj transformacija kod kojih širina prozora nije fiksna – na primjer, *wavelet* transformacije.



Slika 3.3. STFT sa različitim trajanjima prozora. Amplituda je prikazana bojom – što je boja bliža crvenoj, to je amplituda veća

3.3. Valićna (*wavelet*) transformacija

Kao što smo naveli, osnovni problem kod korištenja Fourierove transformacije u kratkom vremenu (STFT) za analizu signala jest taj što se moramo odlučiti za neku fiksnu širinu prozora, što nas ograničava rezolucijom ili u vremenu, ili u frekvenciji – ne možemo otkriti i jedno i drugo sa visokom točnošću.

No, zašto signal ne bi pokušali analizirati sa više prozora različitih trajanja? Pođimo od toga da se niskofrekvencijske komponente u signalu sporo mijenjaju, a visokofrekvencijske komponente se brzo mijenjaju. Analizirajući signal prozorima kraćeg trajanja, čime postizemo dobru vremensku rezoluciju, žrtvujemo preciznost u određivanju frekvencije. Međutim, frekvencije koje se brzo mijenjaju su visoke frekvencije i u praksi nam najčešće nije potrebno njihovo vrlo precizno poznavanje. Na primjer, gušenje ili pojačanje nekog filtra mnogo sporije opada, odnosno raste, na visokim frekvencijama nego

na niskima. Ta činjenica govori nam da je korištenje kratkih prozora za analizu visokofrekvencijskog sadržaja signala opravdano. S druge strane, ako želimo postići dobru rezoluciju u frekvenciji, moramo koristiti dulje prozore, čime gubimo vremensku određenost. No, signali niskih frekvencija, za koje nam je bitno što točnije poznavanje frekvencije, sporo su promjenjivi u vremenu, te tako ima smisla odustati od točnog određivanja njihovog trajanja u vremenu u zamjenu za bolje određenje njihove frekvencije.

Opisane ideje temelj su za tzv. valićnu (*wavelet*) transformaciju. Kao što Fourierovom transformacijom nastojimo signal prikazati kao sumu beskonačno mnogo sinusnih signala različitih amplituda i frekvencija, valićnom transformacijom nastojimo signal prikazati kao sumu određenih valnih oblika, odnosno malih valova - valića.

Valićna transformacija kontinuiranog signala $x(t)$, odnosno, kontinuirana valićna transformacija (*continuous wavelet transform, CWT*) definirana je kao (Polikar, 1999):

$$CWT_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (3.7)$$

Funkcija $\Psi(t)$ naziva se *mother wavelet* funkcija. Slično kao kompleksna eksponencijalna funkcija $e^{-j\omega t}$ kod Fourierove transformacije, ona čini jezgru valićne transformacije. No, za razliku od kompleksne eksponencijalne funkcije koja u sebi sadrži samo parametar ω , frekvenciju, *wavelet* funkcija sadrži dva parametra – pomak τ i skalu s . Očito je i zašto se ti parametri tako zovu: mijenjajući vrijednost parametra τ , funkcija $\Psi(t - \tau)$ pomiče se po t -osi; mijenjajući parametar s , funkcija $\Psi(t/s)$ se steže ili rasteže duž vremenske osi, tj. skalira se.

Vidi se i da je rezultat valićne transformacije funkcija dvije varijable – pomaka i skale – te da ovisi o još jednom faktoru, funkciji korištenoj kao *mother wavelet*.

Iz definicije valićne transformacije vidimo i kako se ona računa. Najprije odaberemo neku skalu s i pomak τ . Na primjer, možemo za početak odabrati $\tau = 0$. Pomnožimo *mother wavelet* funkciju sa tim parametrima sa originalnim signalom $x(t)$, te produkt integriramo po cijeloj vremenskoj osi, od $-\infty$ do $+\infty$. Potom za neki (infinitezimalno) mali iznos pomaknemo vrijednost pomaka τ , te ponovimo postupak. Nakon što smo postupak proveli za sve iznose pomaka τ , promijenimo iznos skale s (opet za infinitezimalno mali iznos), te

ponovno računamo integral za sve iznose pomaka τ . Kada „pokrijemo“ i sve vrijednosti skale s , izračunali smo wavelet transformaciju.

U praksi, slično kao i kod Fourierove transformacije, nećemo računati analitički oblik CWT već njegovu numeričku aproksimaciju, koristeći konačne pomake i skale te samo u onom području u kojem se nalazi analizirani signal.

Kakav je fizikalni smisao rezultata kontinuirane valićne transformacije? Najprije, prisjetimo se definicije korelacije dva signala, $x_1(t)$ i $x_2(t)$:

$$R_{x_1, x_2} = \int_{-\infty}^{\infty} x_1(t)x_2(t + \tau)dt$$

Korelacija mjeri koliko su signali slični. Definicija je praktički ista kao i za valićnu transformaciju. To se uklapa u ono što je već rečeno o valićnoj transformaciji: ona nastoji prikazati signal kao sumu valića različitih skala i vremenskih pomaka. Da bi se odredilo koliko kojeg valića ima u analiziranom signalu, računa se zapravo korelacija analiziranog signala sa svim mogućim valićima nastalima skaliranjem i vremenskim pomicanjem originalnog *mother waveleta*.

Promotrimo sada parametar skale, s , u *wavelet* funkciji. Obzirom da se nezavisna varijabla t u *wavelet* funkciji dijeli sa skalom s , vidimo da je *wavelet* funkcija to rastegnutija po t -osi što je skala veća. Slično kao i kod Fourierove transformacije u kratkom vremenu, korištenje dulje *wavelet* funkcije znači veću rezoluciju u frekvenciji, a manju rezoluciju u vremenu. Već smo zaključili da je takav način analize prikladan za niske frekvencijama. S druge strane, mali iznosi skale stežu *wavelet* funkciju u vremenu, odnosno korespondiraju analizi sa skraćenim prozorom kod STFT. Time povećavamo vremensku, ali smanjujemo frekvencijsku rezoluciju.

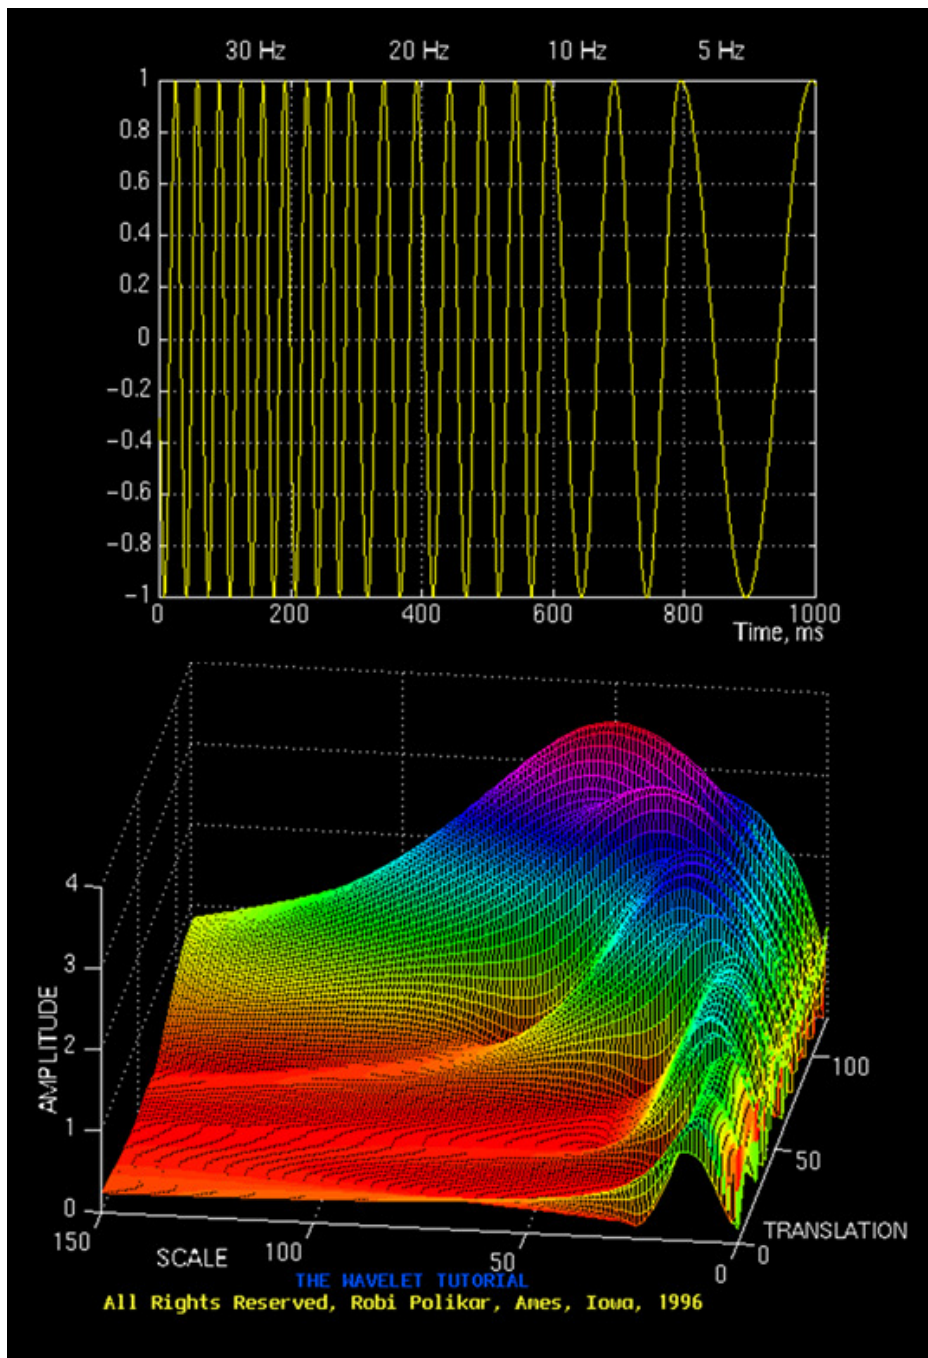
Konačan rezultat kontinuirane valićne transformacije prikazuje udio pojedinih valića u originalnom signalu. Grafički, rezultat valićne transformacije je ploha u prostoru, čija amplituda prikazuje udio pojedinih valića. Na primjer, slika 3.4a prikazuje jedan kontinuirani signal, a slika 3.4b njegovu valićnu transformaciju. Sa slike je jasno vidljivo kako udio niskih frekvencija (koje su reprezentirane velikim skalama) raste prema kraju signala. Također vidimo da je kod niskih skala prijelaz između frekvencija u originalnom signalu oštro naglašen (dakle, imamo bolju vremensku rezoluciju), dočim je kod većih

skala ploha više „razmazana“ kroz razne iznose vremenskog pomaka, to jest, gubimo rezoluciju u vremenu.


Pitanje kojim se dosad nismo bavili jest pitanje oblika *mother wavelet*-a, dakle temeljnog valića na kojem se temelji transformacija. Razvijen je niz standardnih *wavelet* funkcija, od kojih je svaka korisna za različite primjene. Na primjer, neke od standardnih obitelji *wavelet* funkcija, dostupne u programskom paketu Matlab, su:

- Haar wavelet
- Daubechies wavelet
- Mexican hat
- Gaussian wavelet
- Meyer wavelet
- Morlet wavelet
- Shannon wavelets

Slika 3.5 prikazuje *Mexican hat* („meksički šešir“) *wavelet*.



Slika 3.4. Kontinuirani signal i njegova valična transformacija (Polikar, 1999)




Slika 3.5. Mexican hat wavelet

4. Način snimanja EMG signala koji se koriste u ovom radu

Signali koji se koriste u ovom radu nastali su mjerenjem elektromiografske aktivnosti mišića prilikom vertikalnog skoka.

Skok je pokret koji uzrokuje projekciju centra težišta tijela u vis te podizanje stopala od tla. Iz biomehaničke perspektive, vertikalni je skok pokret pri kojem se nastoji postići maksimalna vertikalna brzina centra težišta tijela pri odrazu. Vertikalni skok je prikladan za znanstvena istraživanja jer je ima jednostavnu strukturu kretanja, kojom je moguće simulirati složenija gibanja koja se javljaju u brojnim sportovima. Prisutne su fleksije i ekstenzije, a moguće je promatrati utjecaj ozljeda na eksplozivnu snagu i stabilnost. Pokret se sastoji od tri faze: prva faza obuhvaća pripremu za skok i odraz, druga faza obuhvaća tijelo u zraku i bez kontakta s tlom, a treća faza počinje ponovnim kontaktom s tlom te pokušajem stabilizacije tijela. Te su faze simbolički prikazane na slici 4.1.



Slika 4.1. Faze vertikalnog skoka: prva faza (a, b), druga faza (c), treća faza (d, e) (Kasović, 2007)²

Ispitanici su skakli dvonožno. Skokovi su se odvijali u kontroliranim i ponovljivim laboratorijskim uvjetima. Svaki od motoričkih testova ponavljao se tri puta za redom ili su se u obzir uzimala tri pravilna pokušaja.

Za mjerenje je korišten sustav BTS FREEEMG proizvođača BTS Bioengineering. BTS FREEEMG je opremljen sa 16 sondi za snimanje od kojih svaka teži svega 8 grama te se za potrebe snimanja pričvršćuju na elektrode koje su zalijepljene na ispitanika. Sonde pojačavaju površinski EMG signal, vrše analogno digitalnu pretvorbu te tako nastale

² Na slici je prikazan jednonožni skok.

podatke bežičnim putem šalju u centralnu jedinicu. Centralna jedinica može biti pričvršćena za pacijenta ili biti u njegovoj blizini.

Blizina pojačala i elektrodi bitna je zbog smanjenja artefakata pomaka te utjecaja različitih smetnji. Također, bežična komunikacija koju koristi uređaj omogućuje ispitaniku slobodno kretanje bez osjećanja utjecaja mjerne opreme, te tako omogućava mjerenje u najprirodnijim mogućim uvjetima.

Istovremeno je mjeren površinski EMG signal sa ukupno 12 mišića, po šest sa svake noge, i to: *Gluteus maximus*, *Biceps femoris caput longus*, *Rectus femoris*, *Vastus lateralis*, *Vastus medialis*, *Gastrocnemius medialis*. Signal je uzorkovan s 16 bitnom razlučljivošću te frekvencijom uzorkovanja od 1000 Hz.

Ispitanici su bile profesionalne sportašice – vrhunske rukometašice prve Hrvatske rukometne lige. Snimanje EMG signala su učinili dr. Stanislav Peharec i Petar Bačić u biomehaničkom laboratoriju Poliklinike Peharec u Puli.

5. Određivanje perioda aktivnosti algoritmom zasnovanim na pragu aktivnosti

Jedan od elemenata analize površinskog elektromiografskog signala je i određivanje trenutka aktivacije i trajanja aktivnosti pojedinih mišića. Takve su informacije korisne prilikom istraživanja pokreta, koordinacije mišića, evaluacije rehabilitacijskih postupaka itd. Najčešće korištena metoda za određivanje početka i trajanja mišićne aktivnosti je vizualna inspekcija signala i ručno određivanje početka i kraja aktivnosti koju provodi za to kvalificirana osoba (najčešće liječnik). Ta se metoda smatra relativno točnom, no ponovljivost rezultata je slaba jer je ipak riječ o subjektivnoj odluci osobe koja analizira signal. Iz istog razloga je teško uspoređivati rezultate različitih istraživača. Još jedan nedostatak ručnog određivanja perioda aktivnosti jest vremenska zahtjevnost takvog postupka.

Pored ručnog određivanja perioda aktivnosti, postoje tri osnovna algoritma određivanja početka i trajanja aktivnosti mišića iz snimljenog EMG signala. Ti algoritmi su:

- Algoritmi temeljeni na određivanju praga aktivnosti
- Algoritmi temeljeni na statističkoj evaluaciji hipoteza
- Algoritmi temeljeni na valičnoj transformaciji

Algoritmi temeljeni na određivanju praga aktivnosti su po svojoj koncepciji najjednostavniji i stoga su se prvi i pojavili.

5.1. Algoritam Hodgesa i Buija

Jedan takav algoritam opisuju Paul W. Hodges i Bang H. Bui u svom radu iz 1996. godine. Njihov postupak je bio sljedeći:

- Izvorni EMG signal se propusti kroz kombinaciju niskopropusnog i visokopropusnog filtra
- Tako filtrirani signal se uzorkuje frekvencijom 2000 Hz

- Digitalizirani signal se ponovno propusti kroz još jedan niskopropusni filter – eliptički filter 6. reda
- Preko signala se potom „prelazi“ prozorom koji usrednjuje uzorke (*moving average filter*). Aktivnost se određuje po tome da li srednja vrijednost uzoraka koji upadaju u prozor prelazi unaprijed određen prag ili ne
- Prag za odluku se bira kao odstupanje od osnovne linije snimljenog signala za određen broj standardnih devijacija signala (na primjer, jedna standardna devijacija ili dvostruka vrijednost standardne devijacije i slično), pri čemu se standardna devijacija računa od uzoraka signala na nekom intervalu u kojem nema mišićne aktivnosti

U svom radu, Hodges i Bui variraju frekvenciju eliptičkog niskopropusnog filtra, trajanje prozora u *moving-average* filtru i prag za određivanje aktivnosti, te uspoređuju tako dobivene rezultate sa ručno određenim periodima aktivnosti na istim signalima. Koristili su tri frekvencije niskopropusnog filtra (500 Hz, 50 Hz i 10 Hz), tri duljine prozora za usrednjavanje (10 ms, 25 ms i 50 ms) te tri vrijednosti praga (1, 2 i 3 puta standardna devijacija). Iskušali su svih 27 mogućih kombinacija tih parametara.

Najbolje rezultate pružile su kombinacije 25 ms/3 SD/50 Hz i 50 ms/1 SD/50 Hz, bez obzira na kvalitetu signala. U signalima u kojima je prisutna viša razina šuma, dobrom se pokazala i kombinacija 25 ms/2 SD/50 Hz. Za signale u kojima je razina šuma niska, dobre su rezultate dale i kombinacije 50 ms/2 SD/50 Hz te 10 ms/1 SD/500 Hz. Hodges i Bui su zaključili kako bez obzira na kombinaciju parametara postoji značajna razlika računalno određenih perioda aktivnosti i ručno određenih perioda aktivnosti. Očekivano, greška je bila veća kod signala sa većom razinom šuma. Međutim, ipak postoji značajna korelacija između ručno i automatski određenih perioda aktivnosti, te zaključuju da je greška povezana s automatskim određivanjem perioda aktivnosti sistemska – ista kombinacija parametara na raznim signalima daje otprilike jednaka odstupanja od ručno određenih perioda aktivnosti, uz uvjet da je i razina šuma otprilike jednaka. Dakle, moguće su usporedbe automatski određenih aktivnosti između raznih mišića, ako su signali snimljeni sa sličnom razinom šuma i analizirani jednakim algoritmom.

Što se parametara filtriranja signala tiče, Hodges i Bui zaključuju kako korištenje preniskih graničnih frekvencija (10 Hz) u niskopropusnom filtru, tj. pretjerano zaglađivanje signala, uglavnom dovodi do greške i to u obliku prerane detekcije početka aktivnosti. Previsoke vrijednosti donje granične frekvencije, pak, dovode do kašnjenja detekcije početka aktivnosti zbog toga što brze varijacije amplitude smanjuju prosječnu vrijednost uzoraka koji upadaju u prozor *moving-average* filtra te tako otežavaju detekciju početka aktivnosti. U skladu s tim opažanjima je i gornja granična frekvencija niskopropusnog filtra koja je eksperimentalno utvrđena kao najbolja – 50 Hz.

Ne postoji neki općeniti konsenzus oko preostala dva parametra – trajanja *moving average* prozora te visine praga. Kratki *moving average* prozori čine algoritam osjetljivim na kratkotrajna povećanja amplitude signala, koja mogu biti prouzročena i drugim uzrocima osim mišićne aktivnosti. Slično tome, dugi *moving average* prozori imaju problema sa detekcijom kratkih mišićnih aktivnosti. Visina praga, pak, znatno ovisi o razini šuma u signalu. Nažalost, za ta dva parametra nije moguće naći neku „zlatnu sredinu“, kao u slučaju gornje granične frekvencije filtra, koja bi davala dobre rezultate u svim slučajevima.

5.2. Modificirani klasični algoritam za usporedbu sa algoritmom temeljenim na valićnoj transformaciji

Za potrebe usporedbe sa algoritmom koji koristi valićnu transformaciju, u ovom radu je implementirana varijanta klasičnog algoritma određivanja aktivnosti kakvog su opisali Hodges i Bui. Koraci u tom algoritmu su sljedeći:

- Visokopropusno filtriranje sa donjom graničnom frekvencijom 10 Hz
- Uklanjanje DC komponente iz signala
- Punovalno ispravljanje signala
- Niskopropusno filtriranje signala sa gornjom graničnom frekvencijom 50 Hz
- Određivanje aktivnosti usporedbom razine signala sa pragom aktivnosti. Prag iznosi tri standardne devijacije izračunate na temelju uzoraka u periodu trajanja 25 ms kad se ne očekuje mišićna aktivnost, a uspoređuje se sa vrijednošću dobivenom *moving-average* filtrom duljine 25 ms

- Na tako detektirane razine aktivnosti se primjenjuje postprocesiranje na način da se najprije brišu detektirane aktivnosti koje su kraće od 75 ms, a nakon toga se spajaju aktivnosti koje su razmaknute za manje od 50 ms.

Korišteni niskopropusni i visokopropusni filtri su FIR filtri 49-tog reda, tj. duljine 50 uzoraka. Frekvencije filtara te duljina *moving average* filtra usklađene su s preporukama koje daju Hodges i Bui.

Razlika u odnosu na Hodges i Bui algoritam jest dodani stupanj postprocesiranja. U stupnju postprocesiranja, najprije se brišu detektirane aktivnosti koje su kraće od određenog unaprijed zadanog vremena, a potom se spajaju aktivnosti između kojih je razmak manji od nekog unaprijed zadanog vremena. Bez postprocesiranja, zbog stohastičke prirode EMG signala, algoritam uspijeva detektirati skup kratkih, ali odvojenih aktivnosti. Obzirom da tako dobiveni rezultati ne odgovaraju stvarnoj aktivnosti mišića, dodan je opisan postupak postprocesiranja. Negativna strana takvog postupka jest njegova pristranost – obzirom da se detektirane aktivnosti najprije brišu, a tek onda spajaju, postupak favorizira detekciju neaktivnosti u odnosu na detekciju aktivnosti.


Ideja za takav način postprocesiranja došla je iz rada (Merlo et al., 2003) koji se bavi određivanjem mišićne aktivnosti pomoću valićne transformacije. U svom radu, oni su spajali detektirane aktivnosti između kojih je razmak manji od 125 ms, a brisali aktivnosti kraće od 5 ms. Međutim, u svojoj su analizi koristili EMG signale nastale tijekom hodanja, dočim se u ovom radu bavi signalima koji su nastali prilikom skoka, koji je brži pokret. Stoga su revidirane i vrijednosti vremena spajanja, odnosno brisanja, te se brišu aktivnosti kraće od 75 ms, a spajaju aktivnosti čiji je razmak manji od 50 ms. Do tih se iznosa došlo eksperimentalno³.

Algoritam je implementiran i testiran korištenjem programskog paketa Matlab 7.5.0 (R2007b).


Postupak detekcije aktivnosti ovim algoritmom ilustriran je slikama 5.1.a - 5.1.d. Slika 5.1.a prikazuje izvorni EMG signal. Slika 5.1.b prikazuje kako taj signal izgleda nakon visokopropusnog filtriranja, uklanjanja DC komponente, ispravljanja te niskopropusnog filtriranja i primjene *moving-average* filtra kako bi se signal sastojao od vrijednosti koje se mogu neposredno usporediti s pragom aktivnosti. Slika 5.1.c prikazuje detektiranu

³ Vidi privitak 4.

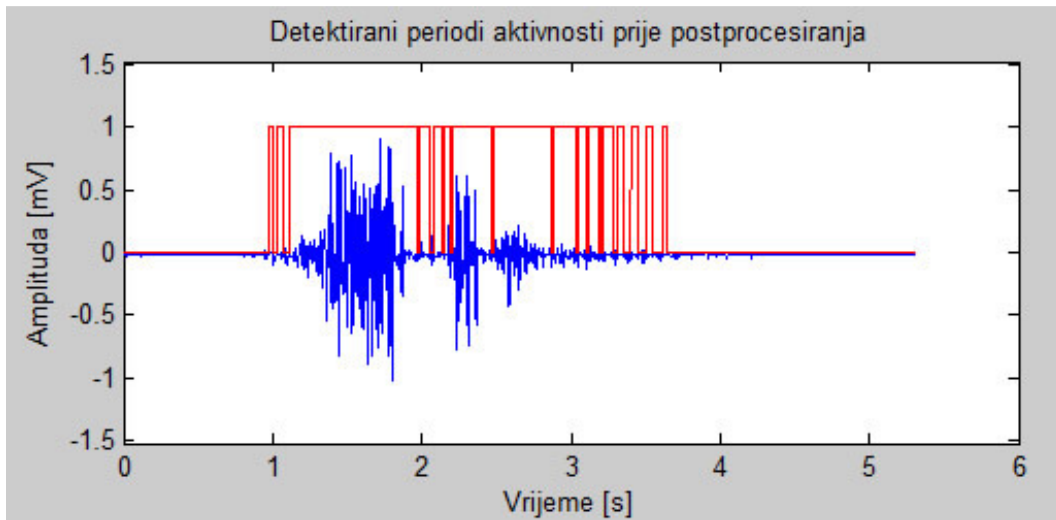
aktivnost na temelju filtriranog signala i praga prikazanog na slici 5.1.b. Vidljivo je kako je algoritam detektirao aktivnost kao niz malih, isprekidanih aktivnosti. Takva detekcija očito ne odgovara stvarnoj situaciji, te se stoga na signal primjenjuje opisano postprocesiranje. Konačna detektirana aktivnost, nakon postprocesiranja, prikazana je na slici 5.1.d.



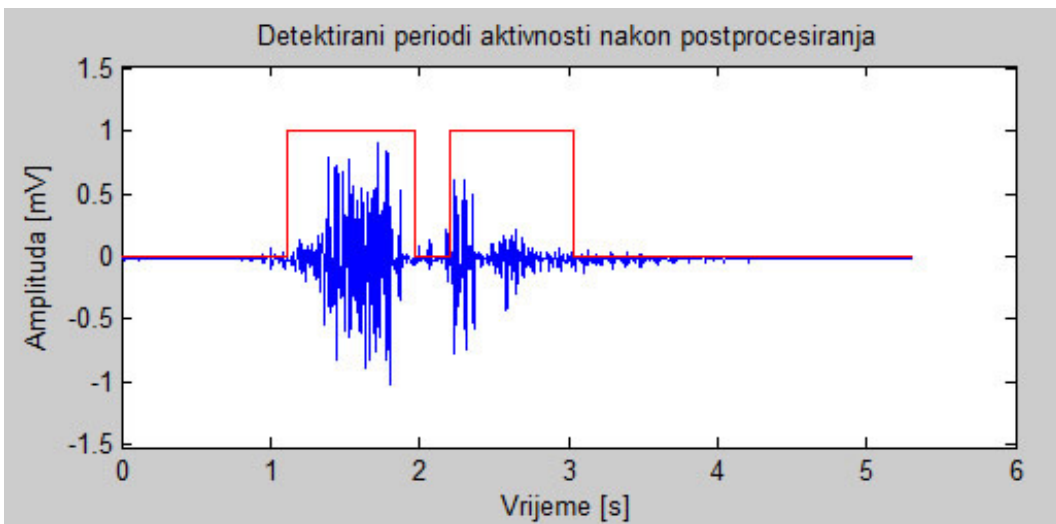
Slika 5.1.a. Izvorni EMG signal



Slika 5.1.b. EMG signal nakon filtriranja, s prikazanim pragom aktivnosti

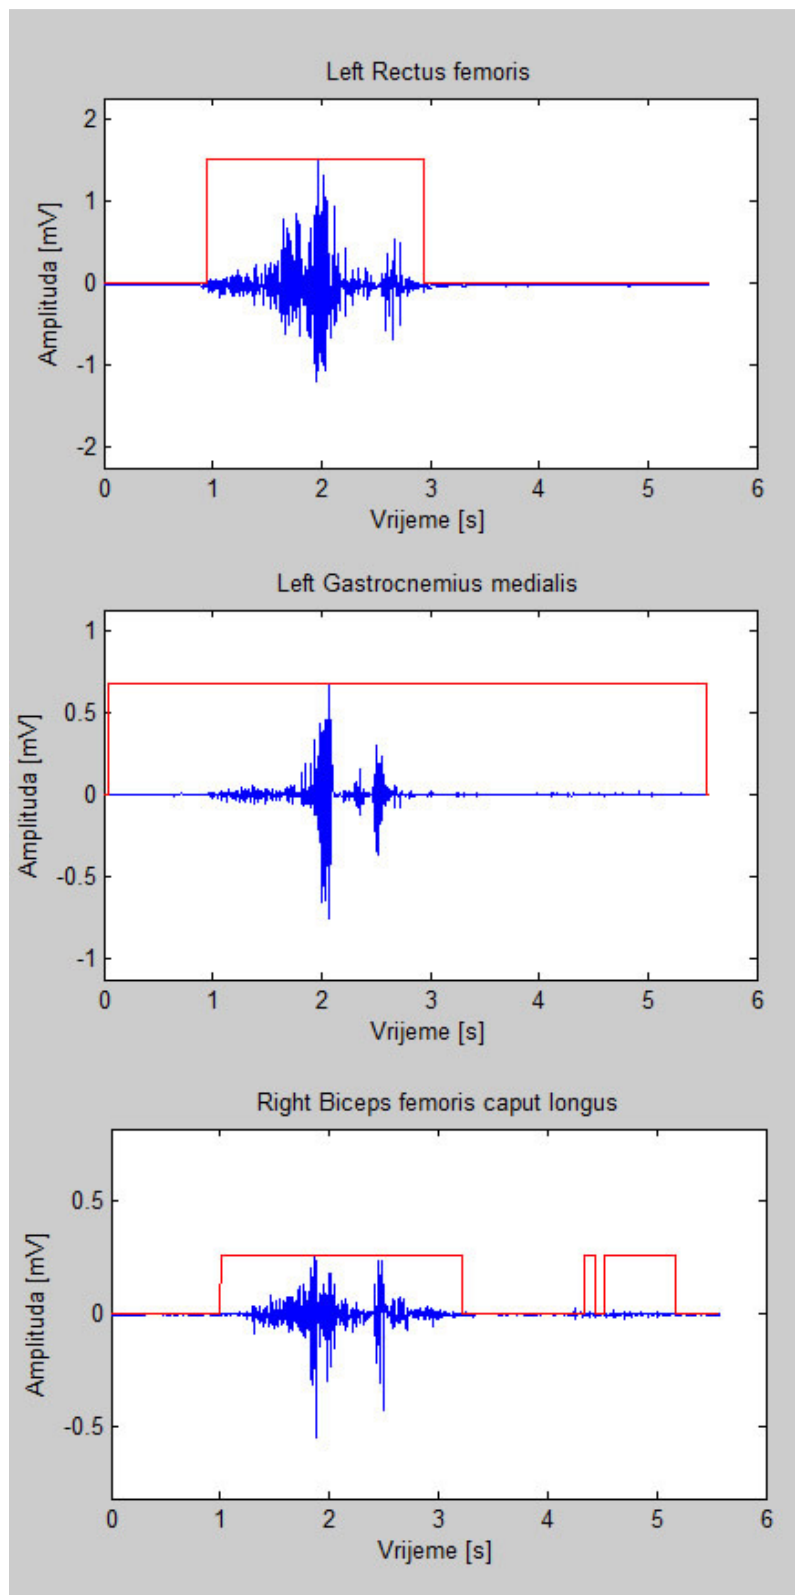


Slika 5.1.c. Periodi aktivnosti detektirani usporedbom signala sa pragom aktivnosti



Slika 5.1.d. Detektirani periodi aktivnosti nakon postprocesiranja

Primjeri signala i aktivnosti detektiranih klasičnim algoritmom prikazani su na slici 5.2.



Slika 5.2. Aktivnosti detektirane algoritmom temeljenim na pragu aktivnosti

Prvi signal (mišić lijevi *Rectus femoris*) primjer je dobro detektirane aktivnosti. U signalu je prisutna niska razina šuma, te se razdoblje aktivnosti jasno ističe. Stoga je i algoritam uspješno detektirao aktivnost.

Drugi signal (mišić lijevi *Gastrocnemius medialis*) je, suprotno od prvog, primjer loše detektirane aktivnosti. Problem u tom signalu je preniska razina šuma u početnom dijelu signala. Zbog toga, standardna devijacija uzoraka iz perioda kad nema mišićne aktivnosti je izrazito mala, pa se stoga već i vrlo mali pomaci signala od nule detektiraju kao aktivnost. Spajanjem bliskih detektiranih aktivnosti u stupnju postprocesiranja dolazimo do toga da se cijeli signal detektira kao aktivnost.

Treći signal (mišić desni *Biceps femoris caput longus*) ima veću razinu šuma od drugog. Stoga kao aktivnost nije detektiran cijeli signal, već neki njegovi dijelovi. Ispravno je detektiran početak mišićne aktivnosti, međutim trajanje je pogrešno određeno. Također, nakon prve aktivnosti detektirane su još i dvije, koje najvjerojatnije nisu postojale, već su posljedica šuma i smetnji nastalih pomakom elektroda i sl.

Dakle, ispravnost rada algoritma temeljenog na pragu aktivnosti ovisi najviše o odnosu između stvarnog EMG signala i šuma. Za određenu kombinaciju parametara algoritma (prag, trajanje *moving average* filtra) loše rezultate daje kako previsoka, tako i preniska razina šuma. Stoga možemo zaključiti da algoritam temeljen na pragu aktivnosti sa fiksno određenim parametrima nije univerzalno primjenjiv, obzirom na velike varijacije u razini šuma i EMG signala između pojedinih mjerenja.

6. Određivanje perioda aktivnosti algoritmom temeljenim na valičnoj transformaciji

U prošlom poglavlju opisan je jednostavan algoritam za određivanje perioda mišićne aktivnosti u EMG signalu koji se temeljio na usporedbi srednje vrijednosti amplitude signala oko nekog trenutka sa pragom aktivnosti. Prag aktivnosti bio je izračunat na temelju amplituda uzoraka signala u onom njegovom dijelu za koji se pretpostavlja da nema mišićne aktivnosti. Jedan od nedostataka te metode je taj što se oslanja samo na amplitudu signala i njeno razlikovanje od amplitude šuma, bez obaziranja na inherentne osobine EMG signala. Takav način detekcije podrazumijeva visok omjer signala i šuma kako bi se ostvarila detekcija mišićne aktivnosti.

Problemi jednostavnog algoritma temeljenog na pragu aktivnosti pokušavaju se riješiti na razne načine. Jedan od načina predložili su 2001. godine u svom radu Andrea Merlo, Dario Farina i Roberto Merletti. Njihov algoritam zasniva se na modelu mišićne aktivnosti kao zbroju doprinosa pojedinih motoričkih jedinica. U tom modelu, svaka motorička jedinica aktivira se tokom mišićne aktivnosti u slučajno vrijeme a bioelektrički signal koji ju pobuđuje na aktivaciju ima slučajnu amplitudu i trajanje (unutar određenih granica). Međutim, kvalitativni oblik signala koji se registrira na površini kože kao posljedicu aktivnosti jedne motoričke jedinice je poznat. Kako je već spomenuto, taj se signal naziva *motor unit action potential* (MUAP). Obzirom da je oblik MUAP signala poznat, snimljeni EMG signal se analizira valičnom (*wavelet*) transformacijom s MUAP funkcijom kao *mother wavelet*-om. Valična transformacija mjeri sličnost signala sa *mother waveletom* određene skale i pomaka; na taj je način moguće odrediti da li se izvorni EMG signal na nekom mjestu sastoji od MUAP-a ili samo od šuma.

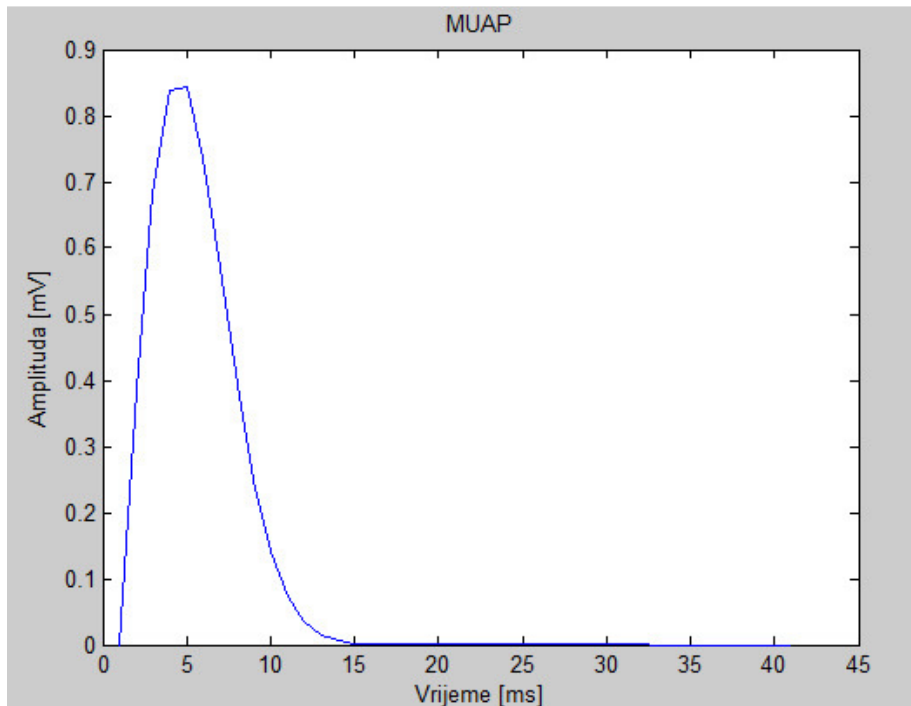
6.1. Matematički model EMG signala

MUAP se može opisati Hermite-Rodriguezovom formulom (Merlo et al., 2003):

$$HR_1(t) = k_{n,1} H_1\left(\frac{t}{\lambda_n}\right) e^{-t^2/\lambda_n^2} \quad (6.1)$$

Pri čemu je $k_{n,1}$ konstanta koja normalizira energiju funkcije na jediničnu vrijednost, $H_1(t)$ je Hermiteov polinom prvog reda, t je vrijeme, a λ_n faktor skale koji određuje trajanje funkcije. Realni MUAP signali imaju trajanje od 5 ms do 40 ms; uzevši u

obzir da je $H_1(t) = 2t$, može se izračunati da parametar skale treba imati vrijednosti 0.002 – 0.018. Jedan takav MUAP signal (izračunan za $\lambda_n = 0.005$) prikazan je na slici 6.1.

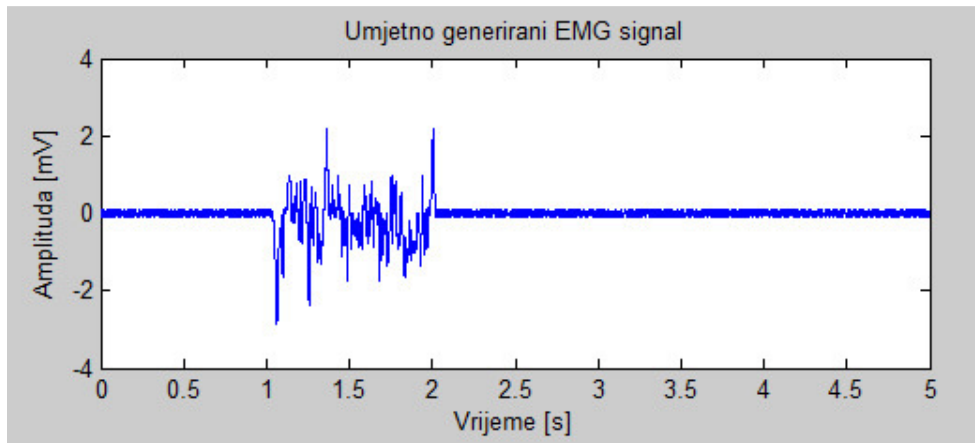


Slika 6.1 . MUAP generiran korištenjem Hermite-Rodriguez formule ($\lambda_n = 0.005$)

EMG koji nastaje kao posljedica mišićne aktivnosti tada se može matematički opisati izrazom

$$s(t) = \sum_j HR_j(t) + n(t) \quad (6.2)$$

Pri čemu je $n(t)$ aditivni šum. Primjer umjetno generirane aproksimacije EMG signala, sa dodanim bijelim šumom, prikazan je na slici 6.2. Period aktivnosti dobiven je zbrojem 100 MUAP signala slučajnog trajanja iz intervala 5-40 ms i slučajne amplitude.



Slika 6.2. Aproximacija EMG signala na temelju njegovog matematičkog modela

6.2. Analiza EMG signala valičnom transformacijom

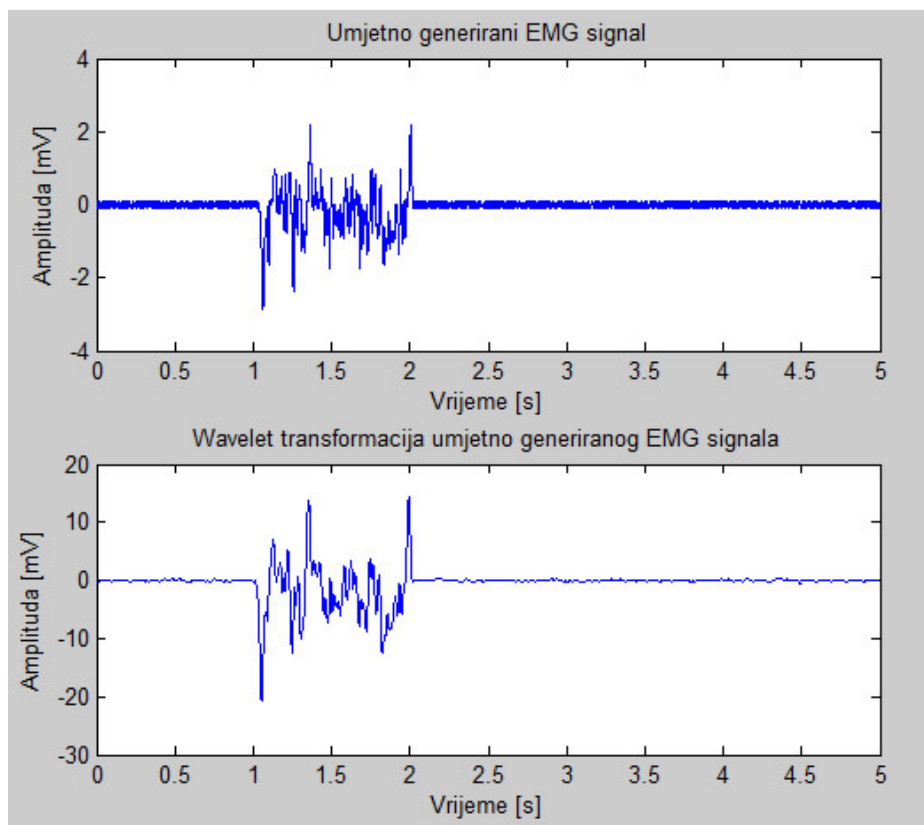
Kako je objašnjeno u trećem poglavlju, valičnom transformacijom se signal prikazuje kao suma „valića“ izvedenih iz *mother wavelet* funkcije mijenjanjem parametara skale i vremenskog pomaka. U svojoj osnovi, valična transformacija određuje udio pojedinih valića u signalu tako što mjeri korelaciju signala sa svakim pojedinim valićem. Ako pretpostavimo da je model EMG signala iznesen u prethodnom odjeljku točan, mišićna aktivnost odvija se u onim trenutcima u kojima je EMG signal sastavljen od MUAP komponenti. Tamo gdje aktivnosti nema, prisutan je samo šum. Primijenimo li na EMG signal valičnu transformaciju sa MUAP funkcijom kao *mother wavelet*-om, očekujemo da ona otkrije na kojim dijelovima EMG signala postoje komponente oblika MUAP funkcije, a upravo su ti dijelovi oni dijelovi u kojima postoji mišićna aktivnost.

U trećem poglavlju navedeno je i način kako se pomoću računala može izračunati aproksimativna valična transformacija nekog signala. U skladu sa opisanim postupkom, valična transformacija EMG signala se može izračunati na sljedeći način:

- Kao *mother wavelet* funkciju odaberemo MUAP funkciju (6.1)
- Parametar λ_n u MUAP funkciji variramo u rasponu 0.002 – 0.018, sa korakom od 0.001. Time se postiže trajanje MUAP funkcije u rasponu od 5 ms do 40 ms, što odgovara realnim fiziološkim MUAP signalima. λ_n stoga ima ulogu skale u valičnoj transformaciji.

- Za svaki odabrani parametar λ_n , izračunamo kros-korelaciju MUAP signala i izvornog EMG signala. Računanje kros-korelacije ustvari odgovara računanju integrala u valičnoj transformaciji za jednu skalu i sve vremenske pomake
- Skup tako izračunatih kros-korelacija predstavlja valičnu transformaciju izvornog EMG signala (odnosno, strogo govoreći, njenu aproksimaciju na jednom dijelu), izračunatu sa MUAP funkcijom kao *mother wavelet*-om. Da bi iz dobivenih 16 signala dobili jedan signal koji možemo analizirati, izračunamo aritmetički sredinu korespondentnih točaka u vremenu.

Ta je ideja ilustrirana slikom 6.3. Ona prikazuje umjetno generirani EMG signal (dobiven izrazima 1 i 2), te njegovu usrednjenu valičnu transformaciju dobivenu gore opisanim postupkom.



Slika 6.3. Umjetno generirani EMG signal i njegova (usrednjena) valična transformacija

Na prvi pogled, vidljivo je povećanje odnosa signala u šuma u transformiranom signalu u odnosu na početni, te se dio koji sadržava aktivnost jasno ističe u odnosu na dio u kojem je prisutan samo šum. Odnos signala i šuma gotovo je 5 puta veći u transformiranom signalu.

To je i očekivano, obzirom da bijeli šum ima vrlo malu korelaciju sa MUAP funkcijom, dočim su različito skalirane i pomaknute MUAP funkcije međusobno visoko korelirane.

Detekcija aktivnosti ponovno se provodi uspoređivanjem amplitude valične transformacije signala sa određenim pragom. U svom radu (Merlo et al., 2003) predlažu sljedeći način određivanja aktivnosti:

- Definira se pomoćna funkcija

$$\eta(t) = \max_{\lambda}(CWT(\lambda, t))$$

Pri čemu je sa $CWT(\lambda, t)$ označena kontinuirana valična transformacija izvornog EMG signala uz λ kao parametar skale

- Prag aktivnosti th tada se izračuna kao

$$M = \max(\eta(t)), t = 0 \dots T_{noise}$$

$$th = \gamma M, \gamma > 1$$

Dakle, kao prag aktivnosti uzima se neki broj veći od maksimalnog iznosa valične transformacije u početnom dijelu izvornog EMG signala u kojem se smatra da nema mišićne aktivnosti. Ukoliko je odnos signala i šuma u izvornom EMG signalu visok, izbor faktora γ nije toliko bitan; za male odnose signala i šuma u izvornom EMG signalu, potrebno je koristiti male vrijednosti $\gamma > 1$.

Nadalje, (Merlo et al., 2003) predlažu naknadnu obradu (postprocesiranje) tako detektiranih aktivnosti na način da se spoje aktivnosti koje su razmaknute za manje od 125 ms, a obrišu aktivnosti kraće od 5 ms.

Međutim, testiranjem algoritma sa takvim načinom određivanja aktivnosti nije dalo osobito dobre rezultate. U nekim signalima, čak i mišićna aktivnost koja se jasno isticala u izvornom EMG signalu nije detektirana, te se čini da je algoritam pristran prema izostanku detekcije, tj. lakše detektira neaktivnost nego aktivnost. No, suprotno tome i neočekivano, u nekim je signalima detektirao i aktivnost tamo gdje je očito nema.

Bolje rezultate dao je postupak određivanja aktivnosti usporedbom s pragom aktivnosti opisan u prethodnom poglavlju, ali primijenjen na valićnu transformaciju EMG signala a ne na sam EMG signal. Dakle, koristi se sljedeći način određivanja perioda aktivnosti:

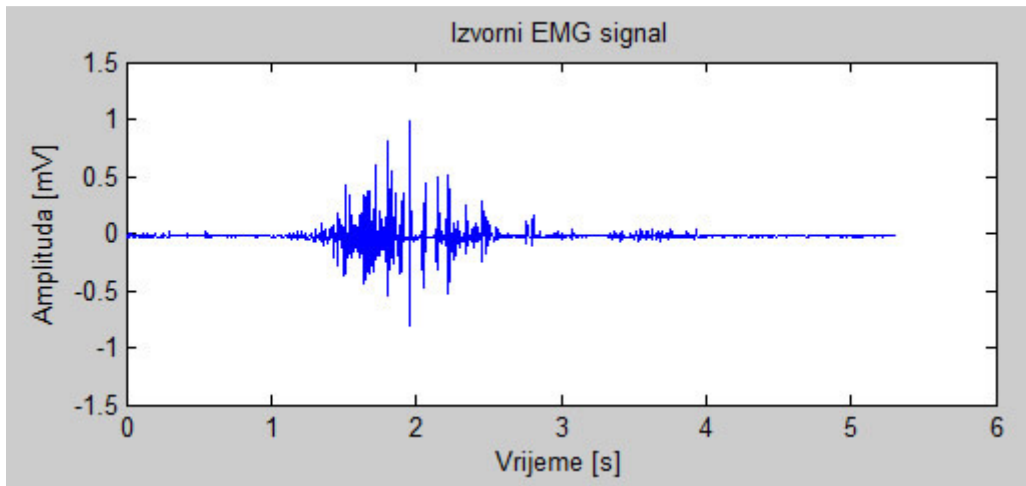
- Prag aktivnosti se izračuna kao tri standardne devijacije valićne transformacije signala u 100 ms u kojima se ne očekuje mišićna aktivnost
- Preko valićne transformacije izvornog EMG signala se prelazi *moving average* filtrom duljine 25 ms. Vrijednost dobivena *moving average* filtrom se uspoređuje sa pragom aktivnosti. Ukoliko je ta vrijednost veća od praga aktivnosti, detektirana je mišićna aktivnost
- Na tako detektirane periode aktivnosti primjenjuje se postprocesiranje kako slijedi:
 - o Detektirane mišićne aktivnosti koje su kraće od 75 ms se brišu
 - o Nakon brisanja prekratkih aktivnosti, detektirane aktivnosti koje su razmaknute za manje od 50 ms se spajaju.

Parametri postprocesiranja drukčiji su od onih koje predlažu (Merlo et al., 2003) iz istog razloga kao i kod algoritma temeljenog na pragu aktivnosti (drugačija priroda mišićne aktivnosti te eksperimentalno opaženi bolji rezultati sa izmijenjenim parametrima)⁴.

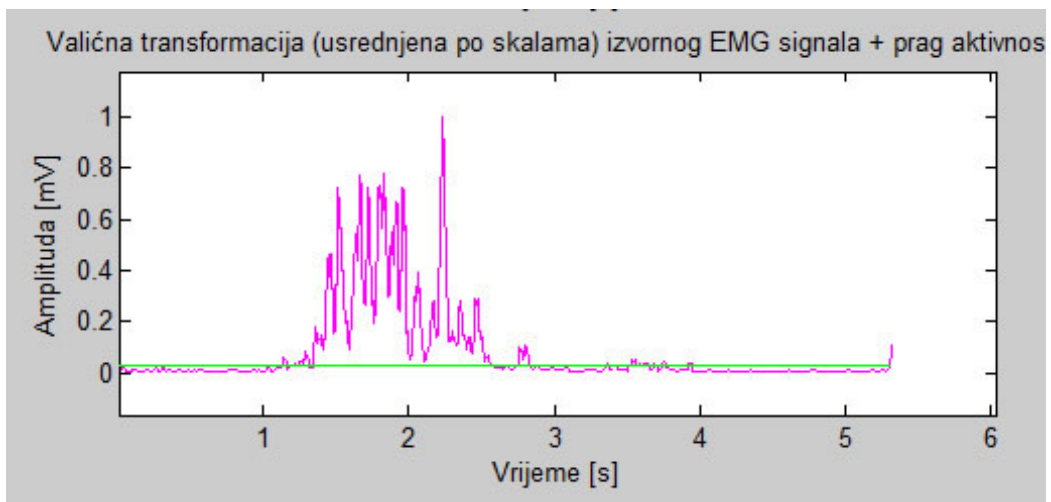
Algoritam je implementiran i testiran korištenjem programskog paketa Matlab 7.5.0 (R2007b).

Slikama 6.4.a – 6.4.d ilustrirani su koraci u određivanju perioda aktivnosti korištenjem valićne transformacije.


⁴ Vidi privitak 4.




Slika 6.4.a. Izvorni EMG signal



Slika 6.4.b. Valična transformacija, usrednjena po skalama, izvornog EMG signala

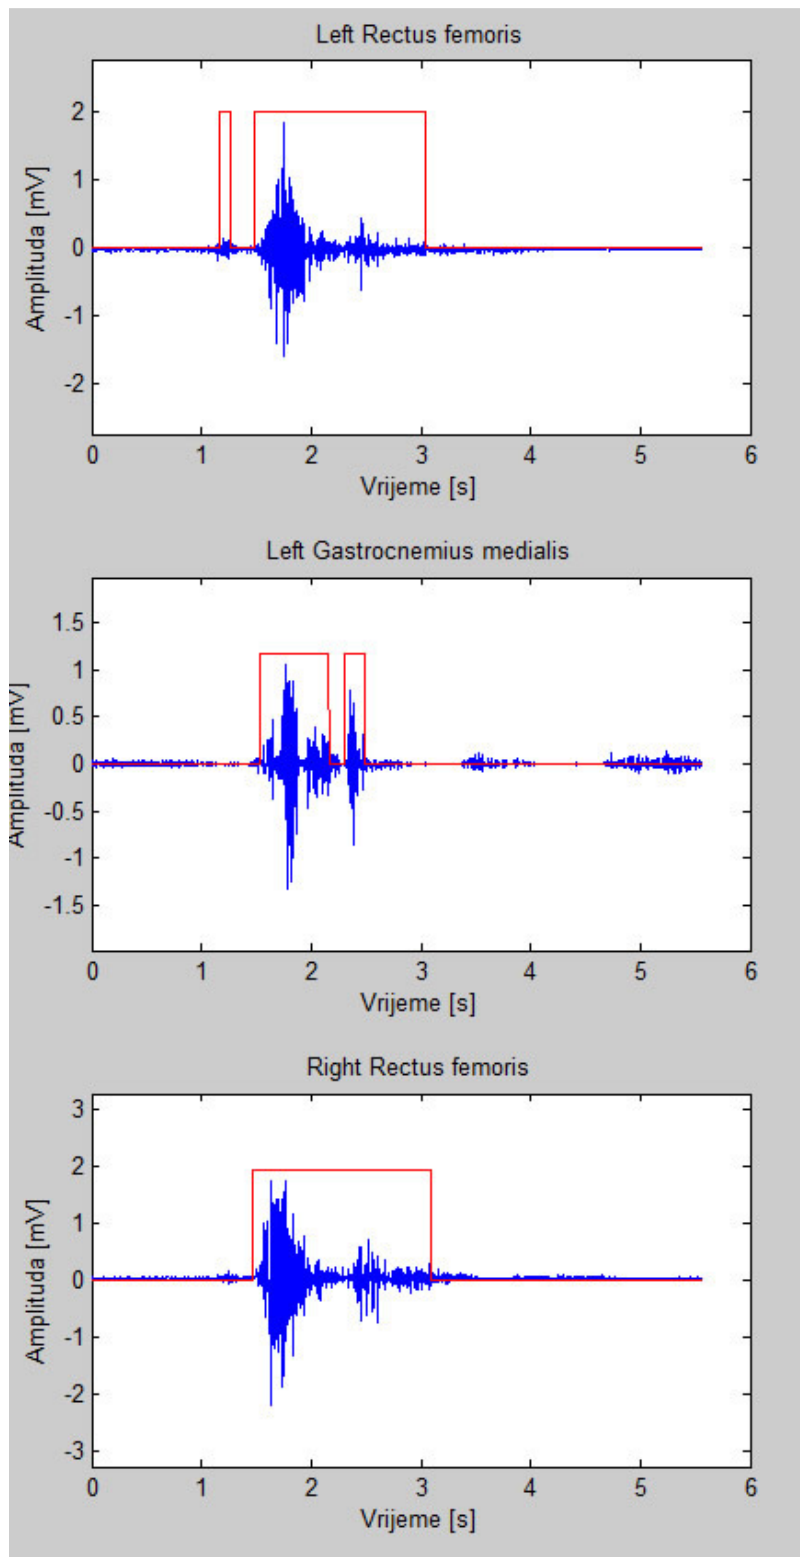


Slika 6.4.c. Mišićna aktivnost detektirana na temelju valične transformacije, prije postprocesiranja



Slika 6.4.d. Mišićna aktivnost detektirana na temelju valićne transformacije nakon postprocesiranja

Rezultati koje daje algoritam koji koristi valićnu transformaciju i gore opisani način određivanja aktivnosti iz valićne transformacije EMG signala prikazani su za neke stvarne EMG signale na slici 6.5.



Slika 6.5. Primjena algoritma sa valičnom transformacijom na realne EMG signale

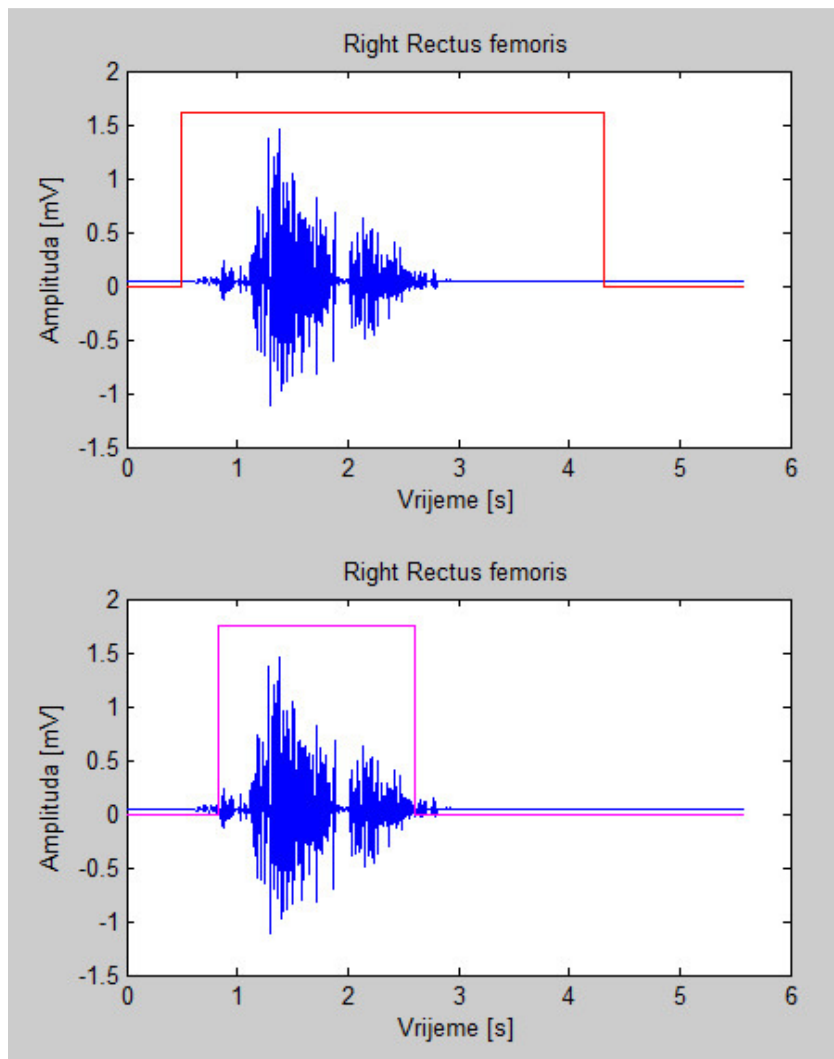
6.3. Problem preniskog praga aktivnosti

Jedan od problema s kojima se tako implementiran algoritam sreće, a koji je prisutan i u algoritmu koji aktivnost određuje jednostavnim prelaskom signala preko praga aktivnosti, jest problem pogrešnih detekcija aktivnosti u signalu koji inicijalno sadrži „prenisku“ razinu šuma. Naime, ako je u početnom dijelu signala razina šuma izrazito niska, i valična transformacija takvog signala će također imati vrlo male vrijednosti na korespondentnom dijelu. Prag aktivnost određen iz tako niske razine šuma je također vrlo mali. Ako se razina šuma u signalu kasnije poveća (što se često dogodi zbog raznih smetnji, pomaka elektroda i slično), zbog premalog praga aktivnosti algoritam će detektirati aktivnosti i tamo gdje ona ne postoji.

Jedan prijedlog rješavanja takvog problema jest da se u signal, prije njegove obrade, doda određena količina bijelog šuma. Na taj se način osigurava da je u signalu u svim trenucima prisutna određena razina šuma. Kako se valičnom transformacijom znatno poboljšava odnos korisnog signala i šuma, ovo dodavanje šuma neće kvariti mogućnost detekcije aktivnosti tamo gdje postoji jasna mišićna aktivnost, a spriječiti će određivanje preniskog praga aktivnosti.

Testiranjem na stvarnim snimljenim signalima pokazalo se da je prihvatljiva razina bijelog šuma koji se dodaje u signal prije valične transformacije 2% od maksimalne amplitude izvornog EMG signala. Utjecaj dodavanja šuma na poboljšanje detekcije aktivnosti u signalu koji inače ima vrlo nisku razinu šuma prikazan je na slici 6.6.

Iako je u većini slučajeva primijećeno da se dodavanjem šuma poboljšava detekcija aktivnosti, u nekim slučajevima dodavanje šuma ipak kvvari detekciju. To se događa kod signala koji sadrže bliske uzastopne aktivnosti koje nisu jasno odijeljene periodom vrlo niskih amplituda u izvornom signalu. Dodavanje dodatnog šuma u takve signale prouzročuje spajanje zasebnih aktivnosti u jednu aktivnost.



Slika 6.6. Poboljšanje detekcije aktivnosti u signalu koji ima vrlo nisku razinu šuma. Detekcija bez dodavanja šuma (gore) ili sa dodavanjem bijelog šuma amplitude 2% od maksimalne vrijednosti izvornog EMG signala prije valične transformacije (dolje).

7. Usporedba algoritama


Kako bi odredili kvalitetu i upotrebljivost pojedinih algoritama za automatsko određivanje neuromuskulatorne aktivnosti, potrebno ih je testirati na većem broju realnih signala te usporediti tako određene periode aktivnosti sa periodima aktivnosti koje je ručnom inspekcijom signala odredio iskusni istraživač. Nažalost, do završetka ovog diplomskog nije dobivena evaluacija signala od strane školovanog istraživača, te je preostala jedino mogućnost usporedbe rezultata između „klasičnog“ algoritma, dakle algoritma zasnovanog na jednostavnom linearnom filtriranju signala i usporedbi njegove amplitude sa pragom aktivnosti, te algoritama koji koriste valićnu transformaciju, u 2 varijante: bez i sa dodavanjem šuma. Kako je već spomenuto, Hodges i Bui su evaluacijom algoritma temeljenog na pragu aktivnosti zaključili da taj algoritam daje rezultate koji odstupaju od ručno određenih perioda aktivnosti, no odstupanje je slično prilikom različitih signala, te se rezultati dobiveni tim algoritmom mogu međusobno uspoređivati te na temelju njih donositi zaključci o pojedinom ispitaniku. Stoga se korištenje rezultata tog algoritma kao referentnih vrijednosti za evaluaciju algoritama temeljenih na valićnoj transformaciji čini opravdanim.

Algoritmi su uspoređeni na sljedeći način: korištenjem algoritma temeljenog na pragu aktivnosti određeni su periodi aktivnosti na svim signalima dobivenima sa 10 ispitanika. Potom su periodi aktivnosti na istim signalima određeni pomoću oba algoritma koji koriste valićnu transformaciju. Za aktivnosti određene pomoću svakog algoritma, određeni su sljedeći parametri: trenutak početka prve detektirane aktivnosti, trenutak kraja posljednje detektirane aktivnosti, omjer ukupnog trajanja detektirane aktivnosti i ukupnog trajanja signala, te ukupan broj detektiranih aktivnosti. Od vrijednosti tih parametara za aktivnosti određene pomoću algoritma s valićnom transformacijom oduzete su vrijednosti istih parametara dobivenih algoritmom temeljenim na pragu aktivnosti. Dobivena razlika čini kvantitativni opis razlike u detekciji aktivnosti između algoritma temeljenog na pragu aktivnosti i algoritma temeljenog na valićnoj transformaciji.

Srednje vrijednosti i standardne devijacije razlika za svaki pojedini mišić sažeto su prikazane u tablicama 7.1 – 7.4 te grafikonima na slikama 7.1 – 7.4.

Tablica 7.1. Razlike trenutaka početka prve aktivnosti između algoritama koji koriste valičnu transformaciju i algoritma temeljenog na pragu aktivnosti


		Razlika trenutaka početka prve aktivnosti (ms)			
		Valična transformacija bez dodavanja šuma		Valična transformacija s dodavanjem šuma	
Redni broj mišića	Mišić	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
1	Lijevi <i>Gluteus maximus</i>	-199,4	210,2	-156,8	112,4
2	Lijevi <i>Biceps femoris caput longus</i>	-110,2	144,0	-47,8	79,1
3	Lijevi <i>Rectus femoris</i>	-58,6	135,4	175,3	370,2
4	Lijevi <i>Vastus lateralis</i>	116,4	500,5	250,1	370,2
5	Lijevi <i>Vastus medialis</i>	864,7	506,9	936,3	487,7
6	Lijevi <i>Gastrocnemius medialis</i>	333,8	814,3	493,9	910,8
7	Desni <i>Gluteus maximus</i>	-100,0	65,2	-86,4	56,8
8	Desni <i>Biceps femoris caput longus</i>	792,5	596,6	818,0	618,4
9	Desni <i>Rectus femoris</i>	-59,5	195,2	58,1	192,4
10	Desni <i>Vastus lateralis</i>	404,5	646,9	417,1	591,0
11	Desni <i>Vastus medialis</i>	365,9	594,6	440,9	534,7
12	Desni <i>Gastrocnemius medialis</i>	347,0	654,1	207,2	505,8
	Srednja vrijednost za sve mišiće	224,8		292,2	
	Standardna devijacija srednjih vrijednosti	339,3		330,1	



Slika 7.1. Grafički prikaz razlika trenutaka početka prve aktivnosti između algoritama koji koriste valičnu transformaciju i algoritma temeljenog na pragu aktivnosti

Tablica 7.2. Razlike trenutaka kraja posljednje aktivnosti između algoritama koji koriste valičnu transformaciju i algoritma temeljenog na pragu aktivnosti

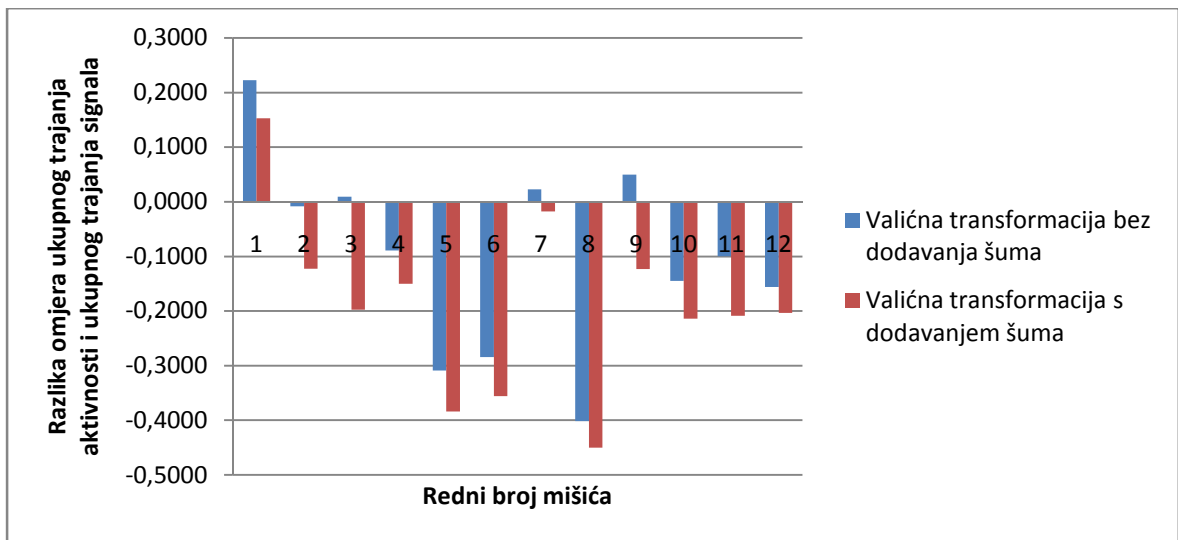
		Razlika trenutaka kraja posljednje aktivnosti (ms)			
		Valična transformacija bez dodavanja šuma		Valična transformacija s dodavanjem šuma	
Redni broj mišića	Mišić	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
1	Lijevi <i>Gluteus maximus</i>	905,9	807,7	881,3	797,3
2	Lijevi <i>Biceps femoris caput longus</i>	-154,3	393,3	-708,8	922,6
3	Lijevi <i>Rectus femoris</i>	528,8	1090,7	-942,3	582,6
4	Lijevi <i>Vastus lateralis</i>	-281,9	1298,4	-763,1	582,6
5	Lijevi <i>Vastus medialis</i>	-1130,7	877,4	-1485,2	951,7
6	Lijevi <i>Gastrocnemius medialis</i>	-1734,6	1419,1	-2037,9	1186,7
7	Desni <i>Gluteus maximus</i>	-287,2	1406,5	-633,9	947,9
8	Desni <i>Biceps femoris caput longus</i>	-1073,2	927,4	-1240,1	978,0
9	Desni <i>Rectus femoris</i>	292,7	1006,7	-392,1	731,1
10	Desni <i>Vastus lateralis</i>	-605,8	1175,8	-1023,9	973,1
11	Desni <i>Vastus medialis</i>	-181,0	1234,5	-808,4	663,2
12	Desni <i>Gastrocnemius medialis</i>	-1639,3	1412,7	-1732,0	1431,7
	Srednja vrijednost za sve mišiće	-446,7		-907,2	
	Standardna devijacija srednjih vrijednosti	790,7		708,7	



Slika 7.2. . Grafički prikaz razlika trenutaka kraja posljednje aktivnosti između algoritama koji koriste valičnu transformaciju i algoritma temeljenog na pragu aktivnosti

Tablica 7.3. Razlike omjera ukupnog trajanja aktivnosti i ukupnog trajanja signala između algoritama koji koriste valićnu transformaciju i algoritma temeljenog na pragu aktivnosti


		Razlika omjera ukupnog trajanja aktivnosti i ukupnog trajanja signala			
		Valićna transformacija bez dodavanja šuma		Valićna transformacija s dodavanjem šuma	
Redni broj mišića	Mišić	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
1	Lijevi <i>Gluteus maximus</i>	0,2224	0,2260	0,1529	0,1958
2	Lijevi <i>Biceps femoris caput longus</i>	-0,0086	0,1569	-0,1225	0,1580
3	Lijevi <i>Rectus femoris</i>	0,0094	0,1294	-0,1975	0,0812
4	Lijevi <i>Vastus lateralis</i>	-0,0893	0,1583	-0,1501	0,0812
5	Lijevi <i>Vastus medialis</i>	-0,3092	0,1795	-0,3840	0,2105
6	Lijevi <i>Gastrocnemius medialis</i>	-0,2845	0,2308	-0,3560	0,2172
7	Desni <i>Gluteus maximus</i>	0,0228	0,1175	-0,0174	0,0993
8	Desni <i>Biceps femoris caput longus</i>	-0,4014	0,2289	-0,4502	0,2494
9	Desni <i>Rectus femoris</i>	0,0497	0,1705	-0,1234	0,1443
10	Desni <i>Vastus lateralis</i>	-0,1446	0,1794	-0,2138	0,1324
11	Desni <i>Vastus medialis</i>	-0,0998	0,2152	-0,2085	0,1288
12	Desni <i>Gastrocnemius medialis</i>	-0,1560	0,1419	-0,2033	0,1521
	Srednja vrijednost za sve mišiće	-0,0991		-0,1895	
	Standardna devijacija srednjih vrijednosti	0,1672		0,1560	



Slika 7.3. Grafički prikaz razlike omjera ukupnog trajanja aktivnosti i ukupnog trajanja signala između algoritama koji koriste valičnu transformaciju i algoritma temeljenog na pragu aktivnosti

Tablica 7.4. Razlike broja detektiranih aktivnosti između algoritama koji koriste valićnu transformaciju i algoritma temeljenog na pragu aktivnosti

		Razlika broja detektiranih aktivnosti			
		Valićna transformacija bez dodavanja šuma		Valićna transformacija s dodavanjem šuma	
Redni broj mišića	Mišić	Srednja vrijednost	Standardna devijacija	Srednja vrijednost	Standardna devijacija
1	Lijevi <i>Gluteus maximus</i>	0,80	1,14	1,20	1,40
2	Lijevi <i>Biceps femoris caput longus</i>	-0,60	1,96	-1,10	1,66
3	Lijevi <i>Rectus femoris</i>	0,50	1,08	0,10	1,60
4	Lijevi <i>Vastus lateralis</i>	-0,60	2,07	-1,10	1,60
5	Lijevi <i>Vastus medialis</i>	-0,70	2,16	0,00	2,40
6	Lijevi <i>Gastrocnemius medialis</i>	-1,80	2,62	-2,00	3,53
7	Desni <i>Gluteus maximus</i>	-0,60	2,32	-0,40	1,96
8	Desni <i>Biceps femoris caput longus</i>	-0,10	2,08	-0,60	1,90
9	Desni <i>Rectus femoris</i>	-0,10	1,29	0,80	1,99
10	Desni <i>Vastus lateralis</i>	-0,80	2,53	-0,10	3,00
11	Desni <i>Vastus medialis</i>	-1,30	2,95	-1,10	3,07
12	Desni <i>Gastrocnemius medialis</i>	-1,70	2,58	-1,70	2,58
	Srednja vrijednost za sve mišiće	-0,58		-0,50	
	Standardna devijacija srednjih vrijednosti	0,76		0,92	



Slika 7.4. Grafički prikaz razlike broja detektiranih perioda aktivnosti između algoritama koji koriste valićnu transformaciju i algoritma temeljenog na pragu aktivnosti

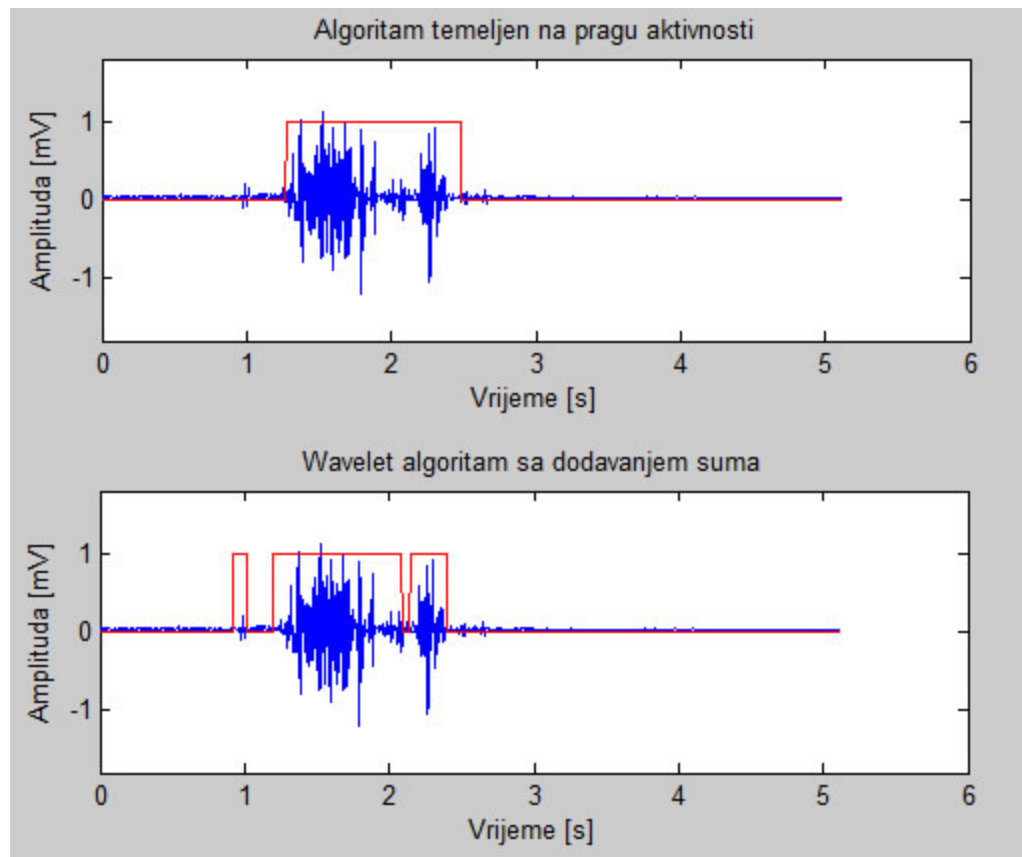
Iz tablica 7.1 – 7.4 te slika 7.1 – 7.4 vidljivo je da je standardna devijacija odstupanja algoritama sa valićnom transformacijom od algoritma s pragom aktivnosti u većini slučajeva veća od prosječne vrijednosti tog odstupanja, te je stoga nemoguće reći da algoritmi koji koriste valićnu transformaciju imaju neku sustavnu razliku u detekciji aktivnosti u odnosu na algoritam koji koristi prag aktivnosti.

Ipak, prosječna vrijednost razlike početka prve detektirane aktivnosti sugerira kako u većini slučajeva algoritam s valićnom transformacijom detektira kasniji početak aktivnosti od algoritma temeljenog na pragu aktivnosti. Jednako tako, algoritam s valićnom transformacijom uglavnom ranije detektira kraj aktivnosti. Manji je i omjer trajanja aktivnosti i ukupnog trajanja signala. Dakle, u prosjeku, algoritam s valićnom transformacijom je strožih kriterija i teže detektira aktivnost od algoritma temeljenog na pragu aktivnosti.

Razlika ta dva algoritma u prosjeku je još i veća kad se pogledaju rezultati algoritma s valićnom transformacijom uz prethodno dodavanje šuma u signal. To je razumljivo, obzirom da dodavanje bijelog šuma povisuje ukupnu razinu šuma prisutnog u signalu i nakon transformacije te tako dodatno povisuje kriterije za detektiranje aktivnosti.

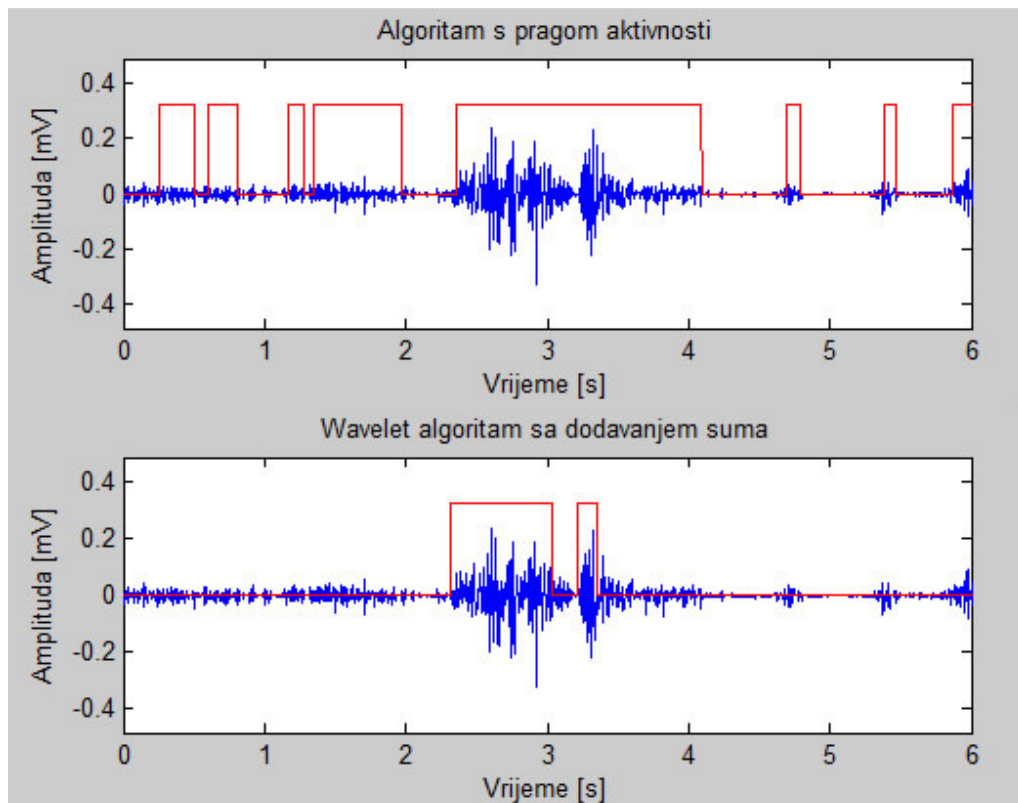
Vidljivo je također i da algoritmi koji koriste valićnu transformaciju uglavnom detektiraju manji ukupni broj aktivnosti, iz čega se može zaključiti da su manje osjetljivi na kratkotrajne poraste amplitude signala, koje su uglavnom posljedica smetnji. Međutim, vizualnim pregledom signala utvrđeno je da tamo gdje algoritmi koji koriste valićnu

transformaciju bolje razlučuju više uzastopnih bliskih aktivnosti od algoritma koji koristi prag aktivnosti. Ovo svojstvo algoritama koji koriste valićnu transformaciju ilustrirano je slikom 7.5, a slaže se i sa zapažanjima koje su iznijeli Merlo, Farina i Merletti (2003.) u svom radu. Posebno je istaknuto kod varijante algoritma sa dodavanjem šuma prije valićne transformacije.




Slika 7.5. Algoritmi koji koriste valićnu transformaciju često bolje razlučuju bliske mišićne aktivnosti od algoritma temeljenog na pragu aktivnosti

Primijećeno je i da se algoritmi koji koriste valićnu transformaciju bolje „snalaze“ u signalima koji od svog početka imaju prisutnu visoku razinu šuma, obzirom da visoka razina šuma u početnim dijelovima signala uzrokuje određivanje „pogrešnog“ praga aktivnosti u algoritmu koji je temeljen na pragu aktivnosti. Jedna takva situacija prikazana je slikom 7.6.



Slika 7.6. Algoritam temeljen na valičnoj transformaciji često daje bolje rezultate za signale koji u svom početnom dijelu sadrže visoku razinu šuma

Nažalost, algoritam koji koristi valičnu transformaciju ponekad čini i grube greške u detekciji aktivnosti. Jedna takva situacija prikazana je slikom 7.7., na kojoj se vidi da je algoritam sa pragom aktivnosti polučio bolje rezultate. U svojim određenim dijelovima izvorni EMG signal prikazan na toj slici ima dijelove koji podsjećaju na oblik MUAP signala. Stoga valična transformacija tog dijela signala ima povišenu amplitudu, te dolazi do detekcije aktivnosti.



Slika 7.7. Za neke signale algoritam temeljen na pragu aktivnosti daje bolje rezultate

8. Zaključak

Automatizacija postupka određivanja neuromuskulatorne aktivnosti značajno bi olakšala, ubrzala te učinila dostupnijom postupke primjene EMG signala u medicini i kineziologiji. Stoga je taj problem predmet znanstvenih istraživanja.

Nažalost, zbog svojstava EMG signala taj problem nije jednostavno riješiti. Površinski EMG signal je signal stohastičke prirode, srednje vrijednosti jednake nuli, te male amplitude, što čini njegovo kvalitetno mjerenje i analizu teškim.

Najjednostavniji i povijesno najstariji algoritam za automatsko određivanje perioda aktivnosti iz površinskog EMG signala koristi usporedbu amplitude filtriranog signala sa pragom aktivnosti, koji se izračunava na temelju samog analiziranog signala. Algoritam daje donekle točne rezultate, no obzirom da je zasnovan isključivo na amplitudi izvornog EMG signala, zahtjeva nisku razinu šuma kako bi davao prihvatljive rezultate.

Stoga je pokušao razvoj algoritama koji bi prepoznavanje neuromuskulatorne aktivnosti temeljili na prepoznavanju karakteristika samog EMG signala u trenucima kad postoji aktivnost. Matematičku podlogu tom postupku daje prikaz EMG signala kao sume MUAP signala opisanih Hermite-Rodriguezovom formulom, te valićna (*wavelet*) transformacija. Valićnom se transformacijom izvorni EMG signal nastoji prikazati kao suma valića (malih valova) koji su oblika MUAP funkcije. Za očekivati je da će se izvorni EMG signal moći najbolje predstaviti MUAP funkcijama u dijelu gdje postoji neuromuskulatorna aktivnost, te će se tako moći odrediti periodi aktivnosti.

Implementacija i testiranje algoritma temeljenog na valićnoj transformaciji pokazala je da se rezultati koji on daje često bitno razlikuju od rezultata dobivenih klasičnim algoritmom temeljenim na pragu aktivnosti. Algoritam temeljen na valićnoj transformaciji u prosjeku je detektirao manje periode aktivnosti i bio selektivniji od klasičnog algoritma. Iskušana je i varijanta algoritma temeljenog na valićnoj transformaciji sa prethodnim dodavanjem male količine šuma u signal. Ta se taktika pokazala dobrom prilikom analize signala koji su snimljeni uz vrlo nisku razinu šuma.

Na žalost, nije bilo moguće evaluirati rezultate algoritma sa valićnom transformacijom putem usporedbe sa ručno određenim periodima aktivnosti, jer oni nisu bili dostupni.

9. Literatura

- [1] Konrad, P. The ABC of EMG: A Practical Introduction to Kinesiological Electromyography. Version 1.0, Noraxon Inc., 2005.
- [2] Hodges, P. W., Bui, B. H. A comparison of computer-based methods for the determination of onset of muscle contraction using electromyography. *Electroencephalography and clinical Neurophysiology* 101, 1996, str. 511 – 519
- [3] Merlo, A., Farina, D., Merletti, R. A Fast and Reliable Technique for Muscle Activity Detection From Surface EMG Signals. *IEEE transactions on biomedical engineering* vol. 50, no. 3., ožujak 2003., str. 316 – 323
- [4] Potočanac, Z. Biomonitoring sustavi. Seminar. FER Zagreb, 2010.
- [5] Potočanac, Z. Analiza površinskih EMG signala nakon ozljede i rekonstrukcije prednjeg križnog ligamenta. Diplomski rad. FER Zagreb, 2008.
- [6] Potočanac Z., Cifrek M.; Peharec S.; Bačić P. Automatic muscle activity onset determination in countermovement jump. FER, Zagreb.
- [7] Babić, H. Signali i sustavi. FER, Zagreb, 1996.
- [8] Polikar, R. *The engineer's ultimate guide to wavelet analysis: the wavelet tutorial*. Svibanj 1999. <http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html> Preuzeto 10.03.2010.
- [9] *Continuous wavelet transform – Wikipedia, the free encyclopedia*. Ožujak 2010. http://en.wikipedia.org/wiki/Continuous_wavelet_transform. Preuzeto 12.03.2010.
- [10] *Wavelet – Wikipedia, the free encyclopedia*. Ožujak 2010. <http://en.wikipedia.org/wiki/Wavelet>. Preuzeto 12.03.2010.
- [11] *Short-time Fourier transform – Wikipedia, the free encyclopedia*. Travanj 2010. http://en.wikipedia.org/wiki/Short-time_Fourier_transform. Preuzeto 05.04.2010.

- [12] *Surface EMG – BTS FREEEMG*. Svibanj 2010.
<http://www.btsbioengineering.com/Electromyography/FREEEMG.html>. Preuzeto
15.05.2010.
- [13] Kasović, M., Mešovšek, M., Medved, V., Lončar, V.: The Role of
musclefatigue on Knee Biomechanics during Single Leg Landings, Proceedings
of the 12th ECSS Congress, Jyväskylä, Finska 2007.

Sažetak

Rad započinje kratkim opisom način nastanka površinskog EMG signala, njegove najvažnije karakteristike, načine mjerenja te temeljne postupke obrade tog signala. Potom su ukratko opisane Fourierova transformacija i Fourierova transformacija u kratkom vremenu, te objašnjena ideja koja stoji iza valićne (*wavelet*) transformacije kao alata za napredniju vremensko-frekvencijsku analizu signala. Nakon opisa snimljenih površinskih EMG signala koji su korišteni prilikom izrade ovog rada, razrađena su dva algoritma za detekciju početka i trajanja neuromuskulatorne aktivnosti na temelju površinskog EMG signala: algoritam temeljen na pragu aktivnosti i noviji algoritam temeljen na valićnoj transformaciji. Rezultati (trenutci početaka i kraja te trajanja aktivnosti) dobiveni na temelju ta dva algoritma su uspoređeni.

KLJUČNE RIJEČI

Elektromiografija, površinski elektromiografski (SEMG) signal, obrada signala, valićna transformacija, određivanje perioda mišićne aktivnosti

Summary

This thesis begins with a brief description of origin of the surface EMG signal, its most important characteristics, methods of measuring it and basic methods used to process it. After that, the Fourier transform and the Short-time Fourier transform are described together with the ideas that are behind the Wavelet transform as a more sophisticated method for time-frequency analysis of signals. After a description of recorded surface EMG signals used in this thesis, a detailed description of the two algorithms for determining neuromuscular activity is given. The two algorithms are the algorithm based on comparing the signal to an activity threshold and the algorithm based on the Wavelet transform. Results obtained using those two algorithms (activity onsets and durations) are compared between each other.

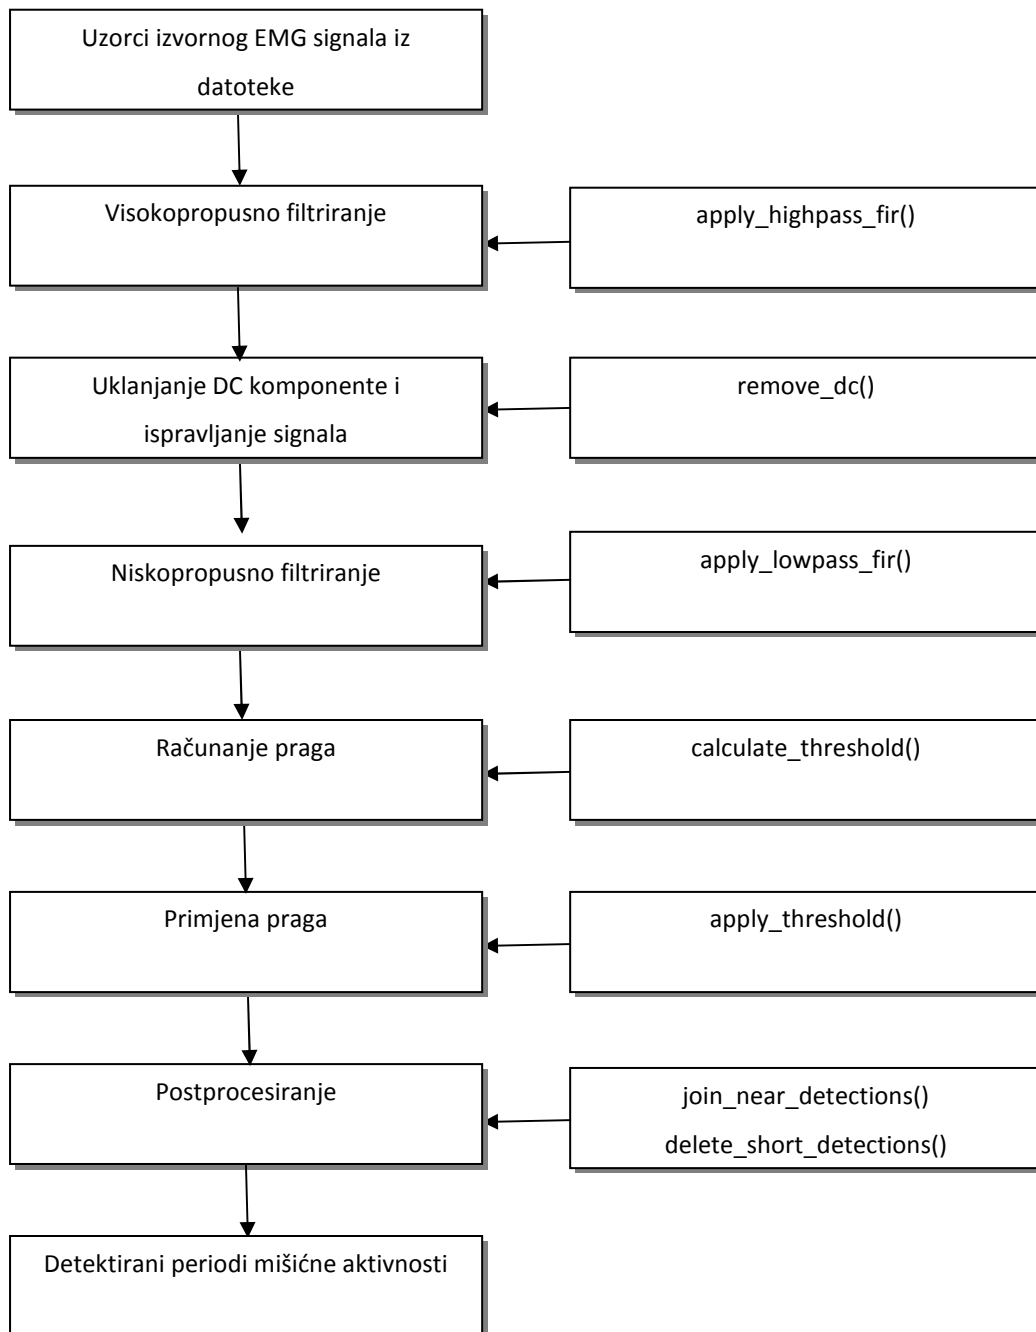
KEYWORDS

Electromyography, surface EMG, signal processing, wavelet transform, muscle activity onset determination

Privitak 1. Programski kod

1. Realizacija algoritma temeljenog na pragu aktivnosti

Na slici 1 dan je shematski prikaz implementacije algoritma za određivanje neuromuskulturne aktivnosti temeljenog na pragu aktivnosti (Hodges & Bui).



Slika 1. Shema realizacije algoritma temeljenog na pragu aktivnosti

classical_analysis()

classical_analysis() je funkcija koja implementira algoritam za detekciju aktivnosti temeljen na pragu aktivnosti. Vraća niz jednake duljine kao ulazni signal koji ima vrijednost 1 u uzorcima u kojima je detektirana aktivnost, a 0 inače. Prima sljedeće parametre:

<i>data</i>	uzorci snimljenog izvornog EMG signala
<i>f_sampling</i>	frekvencija kojom su uzeti uzorci
<i>join_time</i>	vrijeme, u ms, koje određuje koliko najviše smiju biti razmaknute susjedne detektirane aktivnosti da bi bile spojene u jednu aktivnost
<i>delete_time</i>	vrijeme, u ms, koje određuje koliko najmanje mora biti dugačka detektirana aktivnost
<i>do_plot</i>	parametar koji određuje treba li funkcija iscrtati graf sa detaljnim prikazom originalnog signala, obrađenog signala i praga aktivnosti

```
function activity1 = classical_analysis(data, f_sampling, join_time,
delete_time, do_plot)

    %sacuvamo originalni signal za kasnije
    original_data = data;

    % vp filtriranje
    data = apply_highpass_fir(data, 10, f_sampling);

    %uklanjanje dc komponente
    data = remove_dc(data);

    % ispravljanje
    data = abs(data);

    % niskopropusno filtriranje
    data = apply_lowpass_fir(data, 50, f_sampling);

    % izracun praga
    threshold = calculate_threshold(data, 50, 25, 3);

    % primjena praga
    activity = apply_threshold(data, threshold);

    % postprocessing
    activity = delete_short_detections(activity, delete_time);
    activity = join_near_detections(activity, join_time);

    % plotamo signale, ako je to zadano
    if(do_plot == 1)

        %duljina signala
        [a signal_length] = size(data);
```

```

t = linspace(0, signal_length/f_sampling, signal_length);

% grafovi
figure;
subplot(2,1,1);
plot(t, original_data);
title('Klasicni algoritam');
hold on;
plot(t, activity, 'r');
subplot(2,1,2);
plot(t, data);
hold on;
plot(t, activity, 'r');
hold on;
plot(t, ones(1,signal_length)*threshold, 'g');
end;

activity1 = activity;

```

apply_highpass_fir() / apply_lowpass_fir()

apply_highpass_fir() / *apply_lowpass_fir()* su funkcije koje obrađuju signal visokopropusnom, odnosno niskopropusnim FIR filtrom. Vraćaju filtrirani signal.

Parametri su im:

<i>signal</i>	uzorci signala koji se želi filtrirati
<i>f_limit</i>	donja (kod visokopropusnog filtra), odnosno gornja (kod niskopropusnog filtra) granična frekvencija u Hz
<i>f_sampling</i>	frekvencija kojom je uzorkovan signal koji se filtrira

```

function filtered_signal = apply_highpass_fir(signal, f_limit,
f_sampling)

% duljina originalnog signala
[a signal_length] = size(signal);

% izrada filtra
f_limit_d = f_limit/(f_sampling/2); % donja granicna frekvencija,
digitalno
filter_order = 50; % red filtra
highpass_fir = fir1(filter_order, f_limit_d, 'high');

% konvolucija signala s filtrom i skracivanje
signal = conv(signal, highpass_fir);

filtered_signal = signal(1, 1:signal_length);

```

```

function filtered_signal = apply_lowpass_fir(signal, f_limit, f_sampling)

% duljina originalnog signala
[a signal_length] = size(signal);

% izrada filtra

```

```

    f_limit_d = f_limit/(f_sampling/2);    % gornja granicna frekvencija,
digitalno
    filter_order = 50;                    % red niskopropusnog filtra
    lowpass_fir = fir1(filter_order, f_limit_d);

    % konvolucija signala s filtrom i skracivanje
    signal = conv(signal, lowpass_fir);
    %signal = conv(signal, lowpass_filter);

    filtered_signal = signal(1, 1:signal_length);

```

remove_dc()

remove_dc() uklanja istosmjernu komponentu iz signala oduzimanjem srednje vrijednosti signala od samog signala. Kao ulazni parametar uzima uzorke signala, a vraća uzorke tako modificiranog signala.

```

function signal_without_dc = remove_dc(original_signal)
    signal_without_dc = original_signal - mean(original_signal);

```

calculate_threshold()

calculate_threshold() računa prag aktivnosti iz predobrađenog signala. Vraća izračunatu vrijednost praga aktivnosti. Parametri su mu:

<i>original_signal</i>	uzorci predobrađenog signala
<i>offset</i>	broj uzoraka koji se preskaču na početku signala prilikom računanja praga
<i>no_samples</i>	broj uzoraka signala iz kojih se računa prag
<i>stdev_multiplier</i>	koeficijent s kojim se množi standardna devijacija odabranih uzoraka da se izračuna iznos praga

```

function threshold = calculate_threshold(original_signal, offset,
no_samples, stdev_multiplier)
    stdev_data = original_signal(1, offset:(offset + no_samples));
    stdev = std(stdev_data);
    threshold = stdev_multiplier * stdev;

```

apply_threshold()

apply_threshold() pomoću izračunatog praga i predobrađenog signala određuje periode aktivnosti metodom opisanom u poglavlju 5. Vraća niz jednake duljine kao ulazni signal koji ima vrijednost 1 u uzorcima u kojima je detektirana aktivnost, a 0 inače. Parametri su mu:

original_signal uzorci predobrađenog signala
threshold prag aktivnosti

```
function activity1 = apply_threshold(original_signal, threshold)

% duljina originalnog signala
[a signal_length] = size(original_signal);

% usporedba se vrši sa ispravljenim signalom
original_signal = abs(original_signal);

% broj uzoraka, od kojih se racuna sredina i uspoređuje sa pragom
window_samples = 25;

% varijabla u koju ce se stavljati je li prisutna aktivnost na
% određenom uzorku ili ne
activity = zeros(1, signal_length);

% od kojeg uzroka se pocinje gledati?
start_index = 50;

% izracunamo moving average
mov_avg_filter = ones(1, window_samples)/window_samples;
average = conv(original_signal, mov_avg_filter);
average = average(1, window_samples:(signal_length+window_samples-
1));

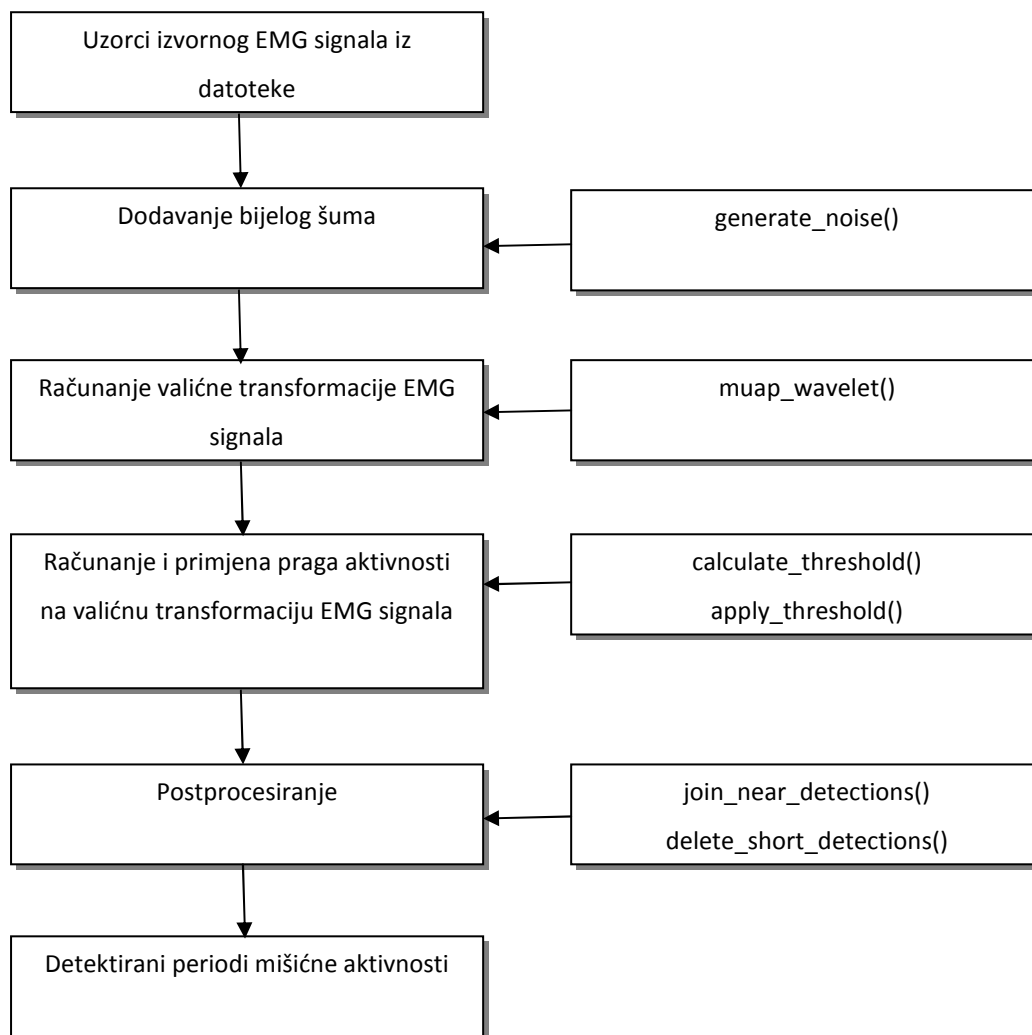
% pomicemo prozor, racunamo prosjek uzoraka koje zahvaca okvir i
% vidimo kakav je taj prosjek
% u usporedbi sa pragom
for i = start_index:(signal_length - window_samples)
    %average = mean(original_signal(i:(i+window_samples)));
    if(average(i) > threshold)
        activity(i) = 1;
    else
        activity(i) = 0;
    end
end

activity1 = activity;
```

Na tako određene aktivnosti primjenjuje se postprocesiranje opisano u poglavlju 5. Obzirom da su funkcije za postprocesiranje jednake za algoritam temeljen na pragu aktivnosti i za algoritam temeljen na valičnoj transformaciji, one će biti navedene naknadno.

2. Realizacija algoritma temeljenog na valičnoj transformaciji

Na slici 2 dan je shematski prikaz implementacije algoritma za određivanje mišićne aktivnosti temeljenog na valičnoj transformaciji.



Slika 2. Shema realizacije algoritma temeljenog na valičnoj transformaciji

Funkcije `calculate_threshold()` i `apply_threshold()` identične su onima opisanima u prethodnome odjeljku.

wavelet_analysis()

`wavelet_analysis()` je funkcija koja implementira algoritam za detekciju aktivnosti temeljen na valičnoj transformaciji. Vraća niz jednake duljine kao ulazni signal koji ima vrijednost 1 u uzorcima u kojima je detektirana aktivnost, a 0 inače. Prima sljedeće parametre:

<code>data</code>	uzorci snimljenog izvornog EMG signala
<code>f_sampling</code>	frekvencija kojom su uzeti uzorci
<code>add_noise</code>	parametar koji određuje dodaje li se bijeli šum u signal prije valične transformacije ili ne
<code>join_time</code>	vrijeme, u ms, koje određuje koliko najviše smiju biti razmaknute susjedne detektirane aktivnosti da bi bile spojene u jednu aktivnost

delete_time

vrijeme, u ms, koje određuje koliko najmanje mora biti dugačka detektirana aktivnost

```
function activity1 = wavelet_analysis(data, f_sampling, add_noise,
join_time, delete_time, do_plot)

    %sacuvamo originalni signal za kasnije
    original_data = data;

    % duljina ulaznog signala
    [a data_length] = size(data);

    % relativna amplituda suma
    noise_max = 0.02;

    % dodamo sum na signal, ako se to trazi
    if(add_noise == 1)
        data_max = max(data);
        noise = generate_noise(-1*data_max*noise_max, data_max*noise_max,
data_length);
        data = data + noise;
    end;

    % wavelet transformacija signala
    [signal_wavelet_t noise_peak] = muap_wavelet(data);

    % dc offset
    start_offset = 50;
    average_period = 100/1000;
    average_samples = average_period * f_sampling;
    dc_offset = mean(signal_wavelet_t(start_offset:start_offset +
average_samples));
    signal_wavelet_t = signal_wavelet_t - dc_offset;

    % racunanje praga za aktivnost
    threshold = calculate_threshold(signal_wavelet_t, start_offset, 100,
3);

    % pomocu parametara odredimo vrijeme aktivnosti emg signala
    activity = apply_threshold(abs(signal_wavelet_t), threshold);

    % postprocessing
    activity = delete_short_detections(activity, delete_time);
    activity = join_near_detections(activity, join_time);

    % plotamo signale, ako je to zadano
    if(do_plot == 1)

        %duljina signala
        [a signal_length] = size(data);
        t = linspace(0, signal_length/f_sampling, signal_length);

        %moving average filter
        mov_avg_filter = ones(1, 25)/25;
        signal_movavg = conv(abs(signal_wavelet_t), mov_avg_filter);
        signal_movavg = signal_movavg(1, 1:signal_length);

        % grafovi
        figure;
```

```

subplot(2,1,1);
plot(t, original_data);
if(add_noise == 1)
    title('Wavelet algoritam sa sumom');
else
    title('Wavelet algoritam bez suma');
end;
hold on;
plot(t, activity, 'r');
subplot(2,1,2);
plot(t, abs(signal_wavelet_t));
hold on;
plot(t, signal_movavg, 'm');
hold on;
plot(t, activity, 'r');
hold on;
plot(t, ones(1,signal_length)*threshold, 'g');
end;

activity1 = activity;

```

generate_noise()

generate_noise() je funkcija koja generira niz slučajnih brojeva. Vraća generirani niz slučajnih brojeva, a parametri su joj:

<i>lower_limit</i>	najmanji slučajni broj koji smije biti prisutan u signalu
<i>upper_limit</i>	najveći slučajni broj koji smije biti prisutan u signalu
<i>no_samples</i>	broj uzoraka od kojih se treba sastojati generirani niz slučajnih brojeva

```

function noise = generate_noise(lower_limit, upper_limit, no_samples)
    noise = lower_limit + (upper_limit - lower_limit)*rand(1,no_samples);

```

muap()

muap() vraća prototip jednog MUAP signala prema Hermite-Rodriguezovoj formuli (poglavlje 6). Vraća niz od 40 uzoraka koji predstavljaju generirani MUAP signal. Kao parametar prima vrijednost λ parametra iz Hermite-Rodriguezove formule.

```

function hr = muap(lambda)

    fs = 1000;                % sampling frequency
    duration = 40/1000;      % duration of the signal, seconds
    t = 0:1/fs:duration;     % time points
    k = 1;

    % izracunamo funkciju

```

```

hr1 = k * 2*t/lambda .* exp(-t.*t/(lambda*lambda));

hr = hr1;

```

muap_wavelet()

muap_wavelet() računa aproksimativnu valićnu transformaciju ulaznog izvornog EMG signala koristeći rezultate *muap()* funkcije kao *mother wavelet*. Vraća niz od dvije vrijednosti:

<i>muap_wavelet_avg</i>	srednja vrijednost izračunatih transformacija za različite skale
<i>noise_wavelet_peak</i>	maksimalna vrijednost valićne transformacije u intervalu 50 – 150 ms (kad se očekuje da je u signalu prisutan samo šum)

Funkcija prima jedan ulazni parametar – niz uzoraka izvornog EMG signala.

```

function [muap_wavelet_avg noise_wavelet_peak] = muap_wavelet(signal)
% skale
scales = 0.002:0.001:0.018;
[a n] = size(scales);

% velicina signala
[a signal_length] = size(signal);

% offset i trajanje perioda izracuna maksimalne vrijednosti
% transformacije suma
noise_offset = 50;
noise_duration = 100;

% varijabla u koju ce se spremiti maksimalan iznos wavelet
% transformacije suma
noise_wavelet_max = 0;

% transformacija za svaku skalu
for i = 1:n
    % muap template za odredjenu skalu
    muap_template = muap(scales(i));
    muap_template = muap_template';

    % proracun wavelet transformacije za odabranu skalu
    signal_wavelet = xcorr(signal, muap_template);
    signal_wavelet = signal_wavelet(signal_length:(2*signal_length-
1));

    %poslozimo wavelet transformacije kao retke matrice
emg_wavelet_final
    signal_wavelet_final(i,:) = signal_wavelet;

    % maksimum waveleta suma u odabranom intervalu
    noise_wavelet_max_tmp = max(signal_wavelet_final(i,
noise_offset:(noise_offset + noise_duration)));
    if(noise_wavelet_max_tmp > noise_wavelet_max)
        noise_wavelet_max = noise_wavelet_max_tmp;
    end;

```



```

end;

%usrednjimo stupce
signal_wavelet_mean = mean(signal_wavelet_final);

muap_wavelet_avg = signal_wavelet_mean;
noise_wavelet_peak = max(signal_wavelet_mean(1,
noise_offset:(noise_offset + noise_duration)));

```

3. Funkcije za postprocesiranje

Funkcije za postprocesiranje spajaju bliske detektirane aktivnosti u jednu aktivnost (*join_near_detections()*) te brišu kratke i izolirane aktivnosti (*delete_short_detections()*).

join_near_detections()

join_near_detections() spaja aktivnosti koje su udaljene za manje od nekog zadanog vremena. Funkcija vraća niz sa tako izmijenjenim uzrocima koji označavaju aktivnost, a kao parametre prima:

<i>activity</i>	niz uzoraka koji označavaju gdje se u originalnom EMG signalu nalazi detektirana aktivnost
<i>join_distance</i>	broj koji označava koliko najviše smiju biti razmaknute aktivnosti (u ms) a da se spoje u jednu aktivnost

```

function processed_activity = join_near_detections(activity,
join_distance)

% duljina originalnog signala
[a signal_length] = size(activity);

% spojimo komadice
for i = 2:signal_length
    if((activity(i) == 0) && (activity(i - 1) == 1))
        distance_to_1 = next_value_distance(activity, i, 1);
        if(distance_to_1 < join_distance)
            activity(i:(i+distance_to_1)) = 1;
            i = i+distance_to_1;
        end
    end
end

processed_activity = activity;

```

delete_short_detections()

delete_short_detections() briše detekcije aktivnosti koje smatramo prekratkima. Funkcija vraća niz sa tako izmijenjenim uzrocima koji označavaju aktivnost, a kao parametre prima:

activity niz uzoraka koji označavaju gdje se u originalnom EMG signalu nalazi detektirana aktivnost

min_length koliko najmanje mora biti dugačka detekcija aktivnosti (u ms)

```
function processed_activity = delete_short_detections(activity,
min_length)

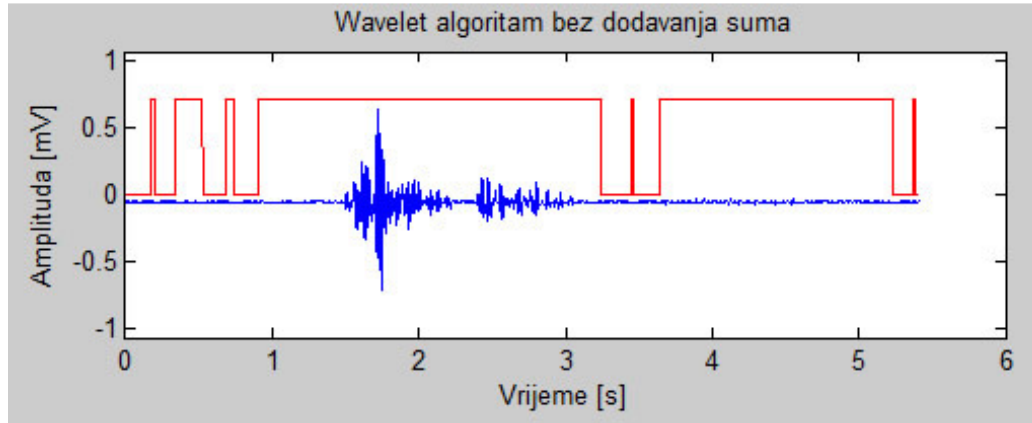
% duljina originalnog signala
[a signal_length] = size(activity);

% obrisemo prekratke
for i = 2:signal_length
    if((activity(i) == 1) && (activity(i - 1) == 0))
        distance_to_0 = next_value_distance(activity, i, 0);
        if(distance_to_0 < min_length)
            activity(i:(i+distance_to_0)) = 0;
            i = i+distance_to_0;
        end
    end
end

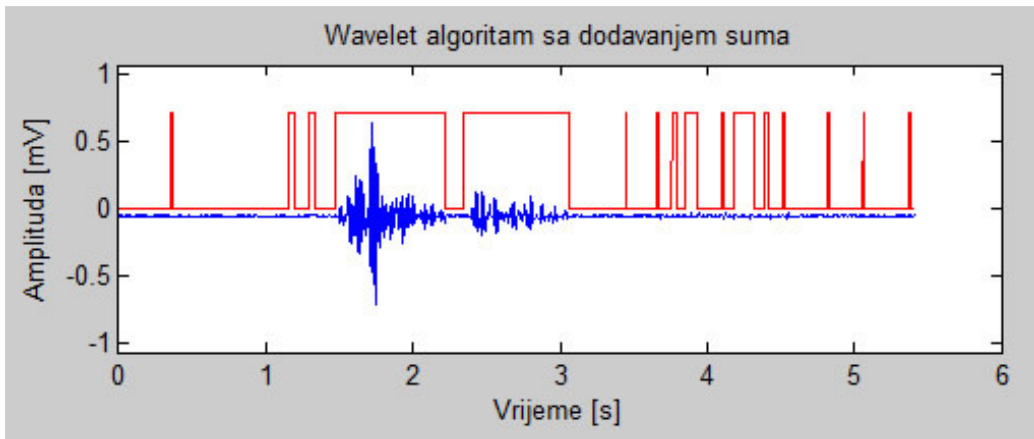
processed_activity = activity;
```

Privitak 2. Određivanje parametara postprocesiranja


U svom radu Merlo, Farina i Merletti (2003.) navode sljedeće parametre postprocesiranja: spajaju se detektirane aktivnosti razmaknute za manje od 125 ms, a brišu se pojedinačne aktivnosti kraće od 5 ms. Međutim, za primjene na signalima korištenima u ovom radu te su vrijednosti neprikladne, kako je ilustrirano slikom 3.a. Spajanje bliskih aktivnosti dovelo je do očigledno pogrešne detekcije aktivnosti. Stoga je najprije pokušano smanjivanje maksimalnog razmaka preko kojeg se spajaju aktivnosti, te slika 3.b. prikazuje rezultate postprocesiranja sa spajanjem aktivnosti koje su razmaknute manje od 50 ms. Rezultati i dalje nisu zadovoljavajući, no jasnije je da je potrebno (znatno) povećati i iznos minimalnog trajanja aktivnosti, kako bi se obrisao velik broj aktivnosti detektiranih zbog kratkotrajnih skokova u signalu. Slika 3.c. prikazuje rezultate dobivene uz brisanje aktivnosti kraćih od 75 ms i spajanje aktivnosti koje su razmaknute manje od 50 ms., što su konačni parametri korišteni u algoritmima u ovom radu. Rezultati slični onima na slikama 3.a. – 3.c. dobivaju se i analizom drugih signala.



Slika 3.a. Rezultati uz postprocesiranje brisanjem aktivnosti kraćih od 5 ms i spajanjem aktivnosti bližih od 125 ms



Slika 3.b. Rezultati uz postprocesiranje brisanjem aktivnosti kraćih od 5 ms i spajanjem aktivnosti bližih od 50 ms



Slika 3.c. Rezultati uz postprocesiranje brisanjem aktivnosti kraćih od 75 ms i spajanjem aktivnosti bližih od 50 ms