

UNIVERZA NA PRIMORSKEM
FAKULTETA ZA MATEMATIKO, NARAVOSLOVJE IN
INFORMACIJSKE TEHNOLOGIJE

DOKTORSKA DISERTACIJA

**METODE ZA AVTOMATSKO OBDELAVO ELEKTROMIOGRAFSKIH
SIGNALOV MIŠIC ČLOVEŠKEGA TRUPA**

ANDREJ PANJAN

KOPER, 2015

MENTOR: IZR. PROF. DR. NEJC ŠARABON
SOMENTOR: DOC. DR. BRANKO KAVŠEK

ZAHVALA

Za mentorstvo, vodenje in pomoč se iskreno zahvaljujem izr. prof. dr. Nejcu Šarabonu.

*Zahvala podjetju S2P d.o.o. za možnost izvedbe programa mladega raziskovalca v
gospodarstvu.*

*Zahvala Javni agenciji Republike Slovenije za spodbujanje podjetništva, inovativnosti, razvoja,
investicij in turizma za sofinanciranje programa mladega raziskovalca v gospodarstvu.*

Zahvala Mateju za pomoč pri izvedbi meritev.

Ne nazadnje neizmerna hvala mojim najbližjim za pomoč, podporo in razumevanje.

Kazalo vsebine

| | |
|---|-----------|
| 1 Uvod | 1 |
| 2 Predmet, problem, namen | 8 |
| 3 Ozadje | 10 |
| 3.1 Predobdelava EMG signala | 11 |
| 3.2 Odstranjevanje EKG motnje iz EMG signala..... | 14 |
| 3.3 Iskanje začetka in konca mišične aktivacije | 17 |
| 3.4 Izračun značilik in klasifikacija..... | 20 |
| 4 Cilji in hipoteze | 24 |
| 4.1 Cilji:..... | 24 |
| 4.2 Hipoteze: | 24 |
| 5 Izvajanje meritev | 25 |
| 5.1 Preiskovanci | 26 |
| 5.2 Priprava merjencev in zajem signalov..... | 26 |
| 5.3 Protokoli meritev | 28 |
| 5.4 Meritve anticipacijskih posturalnih prilagoditev | 28 |
| 5.5 Meritve posturalnih reakcij na obremenitev | 29 |
| 6 Obdelava podatkov | 31 |
| 6.1 Čiščenje podatkov | 31 |
| 6.2 Predobdelava EMG signalov | 32 |
| 6.3 Odstranjevanje EKG motnje iz EMG signala..... | 35 |
| 6.3.1 Preizkušani pristopi za odstranjevanje EKG motnje..... | 36 |
| 6.3.2 Nova metoda za odstranjevanje EKG motnje iz EMG signala | 39 |
| 6.3.2.1 Dinamično časovno sledenje..... | 40 |
| 6.3.2.2 Iskanje podzaporedij z dinamičnim časovnim sledenjem | 44 |
| 6.3.2.3 Podroben opis nove metode za odstranjevanje EKG motnje iz EMG signala | 46 |

| | |
|---|-----------|
| 6.3.3 Vrednotenje nove metode za odstranjevanje EKG motnje iz EMG signala | 50 |
| 6.3.3.1 Vrednotenje uspešnosti predlagane metode na umetno ustvarjenih EMG signalih..... | 51 |
| 6.3.3.2 Vrednotenje uspešnosti predlagane metode na realnih EMG signalih..... | 54 |
| 6.3.4 Razprava in zaključek..... | 57 |
| 6.4 Iskanje začetka in konca mišične aktivacije..... | 61 |
| 6.4.1 Pregled pomanjkljivosti do sedaj predlaganih metod za iskanje začetka in konca mišične aktivacije | 62 |
| 6.4.2 Nova metoda za iskanje začetka in konca mišične aktivacije..... | 65 |
| 6.4.3 Vrednotenje metode za iskanje začetka mišične aktivacije | 72 |
| 6.4.4 Razprava in zaključek..... | 75 |
| 6.5 Izračun značilke in klasifikacija | 76 |
| 6.5.1 Značilke..... | 76 |
| 6.5.1.1 Obdelava EMG signala za izračun značilke..... | 77 |
| 6.5.1.2 Značilke v časovni domeni..... | 77 |
| 6.5.1.3 Značilke v frekvenčni domeni..... | 79 |
| 6.5.1.4 Značilke v časovno-frekvenčni domeni | 80 |
| 6.5.2 Klasifikacijske metode | 80 |
| 6.5.3 Uspešnost klasifikacije za iskanje bolnih preiskovancev | 81 |
| 6.5.4 Razprava in zaključek..... | 82 |
| 7 Aplikacija za avtomatsko obdelavo EMG signalov | 84 |
| 8 Zaključek..... | 87 |
| 9 Literatura | 91 |

Kazalo slik

| | |
|--|----|
| Slika 5.1: Namensko izdelana merilna naprava za izvajanje meritev..... | 25 |
| Slika 5.2: Postavitev EMG elektrod na levi polovici telesa..... | 27 |
| Slika 5.3: Izvajanje APP naloge..... | 29 |
| Slika 5.4: Izvajanje PRO naloge..... | 30 |
| Slika 6.1: Uporaba visoko pasovnega filtra za odstranjevanje nizko frekvenčnih motenj. | 33 |
| Slika 6.2: Primer odstranjevanja šuma z DVT..... | 34 |
| Slika 6.3: Postopek odstranjevanja EKG motnje iz EMG signala s kombinacijo CEEMD in ICA... | 37 |
| Slika 6.4: Postopek odstranjevanja EKG motnje iz EMG signala s kombinacijo EVT in ICA..... | 39 |
| Slika 6.5: Časovna poravnava dveh časovno odvisnih zaporedij. | 41 |
| Slika 6.6: Grafična predstavitev pogoja velikosti koraka..... | 41 |
| Slika 6.7: Matrika akumuliranih cen..... | 43 |
| Slika 6.8: Primer predloge prezrcaljene preko časovne osi. | 48 |
| Slika 6.9: Primer variabilnost EKG artefakta za tri različne preiskovance..... | 48 |
| Slika 6.10: Primera EMG signala z EKG motnjo tipa 1 (A) in tipa 2 (B)..... | 51 |
| Slika 6.11: Predloge, uporabljene za testiranje uspešnosti nove metode za odstranjevanje EKG motnje iz EMG signala..... | 53 |
| Slika 6.12: Primer odstranjevanja šibke EKG motnje iz EMG signala..... | 59 |
| Slika 6.13: Primer odstranjevanja EKG motnje iz EMG signala za primer sovpadanja EKG artefakt z začetkom mišične aktivacije. | 60 |
| Slika 6.14: Primer iskanja začetka mišične aktivacije z metodo Hodges in Bui..... | 63 |
| Slika 6.15: Primer slabo postavljenega osnovnega okna metode AGLRstep..... | 64 |
| Slika 6.16: Primer izračuna funkcij p in q | 67 |
| Slika 6.17: Primer lokalnega nihanja amplitude in primer šibkejše začetne mišične aktivacije, kateri sledi močnejša mišična aktivacija. | 69 |
| Slika 6.18: Primer napačne določitve tZA | 71 |
| Slika 7.1: Primer zaslona za preverjanje in postavljanje začetka mišične aktivacije..... | 85 |

Kazalo tabel

| | |
|--|----|
| Tabela 6.1: Rezultati vrednotenja uspešnosti odstranjevanje EKG motnje iz EMG signala na umetno ustvarjenih EMG signalih. | 53 |
| Tabela 6.2: Rezultati testiranja zaznave EKG motnje v EMG signalu na realnih signalih. | 56 |
| Tabela 6.3: Rezultati testiranja uspešnosti odstranjevanja EKG motnje iz EMG signala na realnih signalih. | 57 |
| Tabela 6.4: Rezultati uspešnosti zaznavanja prisotnosti mišične aktivacije v EMG signalu. | 73 |
| Tabela 6.5: Rezultati primerjave določanja začetka mišične aktivacije v EMG signalu med različnimi metodami. | 74 |

Izvleček: Metode za avtomatsko obdelavo elektromiografskih signalov mišic človeškega trupa

Doktorska disertacija obravnava problem avtomatske obdelave elektromiografskih (EMG) signalov človeškega trupa pri meritvah anatičipatornih posturalnih prilagoditev in posturalnih refleksnih odzivov, ki sta podvrsti samodejnih posturalnih akcij trupa. Z rešitvijo tega problema smo želeli odpraviti zamudno in monotono ročno delo, ki je neizbežno pri postopku obdelave EMG signalov. Obdelava EMG signala poteka zaporedno po sledečih stopnjah: predobdelava EMG signala, odstranjevanje elektrokardiografske (EKG) motnje iz EMG signala, iskanje začetka in konca mišične aktivacije ter izračun značilk in klasifikacija.

V stopnji predobdelave EMG signala se odstranjuje motnje (šum) iz EMG signala. Za ta namen smo uporabili dve metodi: Butterworth pasovno prepustni filter in odstranjevanje šuma z diskretno valčno transformacijo.

Za potrebe odstranjevanja EKG motnje iz EMG signala smo razvili novo metodo, ki temelji na dobro uveljavljeni metodi dinamičnega časovnega sledenja. Za razvoj nove metode smo se odločili zaradi nezanesljivosti in/ali neprimernosti obstoječih metod za avtomatsko obdelavo EMG signalov. Predlagana metoda se je izkazala za zanesljivo pri zaznavi prisotnosti EKG motnje v EMG signalu in hkrati za uspešno pri odstranjevanju EKG motnje iz EMG signala.

Za iskanje začetka in konca mišične aktivacije v EMG signalu smo prav tako razvili novo metodo. Tudi tukaj smo se za razvoj nove metode odločili zaradi nezanesljivosti in/ali neprimernosti obstoječih metod za avtomatsko obdelavo EMG signalov. Nova metoda se je pokazala za zanesljivo pri zaznavanju prisotnosti mišične aktivacije v EMG signalu in je bila hkrati uspešnejša od obstoječih metod pri iskanju začetka mišične aktivacije.

Za potrebe zadnje stopnje obdelave smo uporabili širok nabor značilk za ovrednotenje EMG signala in dve klasifikacijski metodi za napovedovanje bolečine v spodnjem delu hrbta ter identifikacije mišic s tveganim vzorcem aktivacije. Izkazalo se je, da tega ne moremo narediti zanesljivo. Sklepamo, da EMG signali človeškega trupa vsebujejo premalo informacije za napovedovanje bolečine v spodnjem delu hrbta in identifikacije mišic s tveganim vzorcem aktivacije. Predvidevamo, da bi večjo uspešnost napovedovanja dosegli z uporabo dodatnih testov za ovrednotenje živčno-mišične funkcije ledveno-medeničnega predela trupa.

Na koncu smo vse stopnje obdelave EMG signalov združili v aplikacijo za avtomatsko obdelavo EMG signalov človeškega trupa, ki ima naslednje prednosti v primerjavi s pretežno ročno

obdelavo EMG signalov: odprava ročnega obdelovanja, hitra obdelava velikih količin podatkov, velik prihranek časa, objektivna obdelava podatkov, možnost postopne ročne obdelave, vizualizacija poteka obdelave v vseh stopnjah, shranjevanje rezultatov obdelav po stopnjah v primerni obliki za nadaljnjo uporabo.

Predstavljena aplikacija za avtomatsko obdelavo EMG signalov človeškega trupa je primerna za uporabo v raziskovalne namene pri stabilizaciji trupa, kakor tudi za uporabo v klinični praksi. Obe novo razviti metodi (za odstranjevanje EKG motnje in iskanje začetka in konca mišične aktivacije) sta primerni za uporabo tudi na EMG signalih, ki niso zajeti na mišicah človeškega trupa.

Ključne besede: avtomatska obdelava EMG signalov, odstranjevanje EKG motnje, iskanje začetka mišične aktivacije, bolečina v spodnjem delu hrbta.

Abstract: Methods for automatic processing of electromyography signals of human trunk muscles

This doctoral thesis addresses the problem of automatic processing of electromyography (EMG) signals of human trunk when measuring anticipatory postural adjustments and postural reflex responses, which are subtypes of automatic postural actions of trunk. Our intention was to eliminate time consuming and monotonous manual work which is inevitable in processing EMG signals. Processing of EMG signals is done in the following successive phases: preprocessing of EMG signal, electrocardiograph (ECG) artifacts removal, onset and offset detection of muscle contraction, and calculation of features and classification.

In the phase of preprocessing of EMG signal, we eliminate noise from EMG signal. We used two methods for this purpose: Butterworth band-pass filter and noise cancellation with discrete wavelet transform.

We developed a new method for ECG artifact removal from EMG signal based on dynamic time warping which is a well-known method. The decision to develop a new method was based on unreliability and/or unsuitability of existing methods for automatic processing of EMG signals. The proposed method proved to be reliable for detection of ECG artefacts in EMG signal and to be successful in ECG artifacts removal from EMG signal.

We also developed a new method for onset and offset detection of muscle contraction. The decision to develop a new method was also based on unreliability and/or unsuitability of existing methods for automatic processing of EMG signals. The proposed method proved to be reliable for detection of muscle activation and it was more successful in onset detection of muscle activation compared to existing methods.

For the purpose of the last phase of processing we used wide range of features for EMG assessment and two classification methods for prediction of low back pain as well as for identification of muscles with bad activation pattern. We showed that this cannot be done reliably. This may be due to inadequate information from EMG signals of human trunk for prediction of low back pain and for identification of muscles with bad activation pattern. We foresee that we can achieve better prediction power with a use of additional tests for assessment of lumbar-pelvic neuromuscular function.

All phases of EMG signal processing were combined into an application for automatic processing of EMG signals from human trunk. The application has following advantages over

mostly manual processing of EMG signals: elimination of manual processing, fast processing of large amount of data, time saving, objective processing of data, possibility of manual processing by phases, visualization of data processing in all phases, storage of results in all phases in suitable format for further processing.

The application for automatic processing of EMG signals from human trunk is suitable for the use in research purposes in human trunk stabilization, as well as for the use in clinical practice. Both new methods (for ECG artifact removal and for onset and offset detection of muscle contraction) are suitable also for processing of EMG signal that are not from human trunk muscles.

Key words: automatic processing of EMG signals, ECG artifacts removal, onset and offset detection of muscle contraction, low back pain.

1 Uvod

Človek se je evolucijsko prelevil iz štirinožnega bitja v pokončno dvonožno bitje, kar je prineslo številne anatomske in funkcionalne spremembe. Na eni strani se je povečala zahtevnost vzdrževanja stabilnosti pokončne drže, medtem ko se je mobilnost na drugi strani povečala. Prve okončine so se prelevile iz nog v roke, ki omogočajo rokovanje s predmeti in s tem v več ozirih povečujejo učinkovitost vrste. Največje spremembe so se zgodile v predelu hrbtenice, ki pri človeku nosi celotni zgornji del telesa. Postala je podvržena večjim obremenitvam, še posebej v spodnjem delu hrbta in medenici. Skladno s tem se je spremenila tudi funkcija mišic. Mišice morajo zagotavljati ohranjanje pokončne drže in ravnotežja telesa, kar je z zmanjšanjem podporne površine in povišanjem centralnega težišča telesa postala zelo zahtevna naloga.

Drža je opredeljena kot relati ven položaj posameznih delov telesa med seboj in njihov položaj v prostoru. Ključen dejavnik pri uravnavanju drže je premagovanje sile gravitacije. Ravnotežje je opredeljeno kot stanje, v katerem so vse sile, ki delujejo na telo, v takšnem razmerju, da telo miruje (statično ravnotežje) ali da je zmožno izvesti predviden gib in pri tem ohraniti ravnotežje (dinamično ravnotežje) (Kandel, Schwartz, & Jessell, 2000). Ravnotežje telesa je zagotovljeno takrat, ko je projekcija težišča znotraj podporne površine. Če telo izgubi ravnotežje, začne padati. Vzdrževanje pokončne drže je aktiven proces, kar se odraža v nenehnem rahlem gibanju težišča telesa. K njenemu vzdrževanju prispevajo tako pasivne kot aktivne strukture. Drža je stabilna, dokler lahko notranje sile uspešno premagujejo razne motnje na telo (Bouisset & Do, 2008).

Ključen dejavnik pri vzdrževanju pokončne drže je stabilizacija hrbtenice (Barr, Griggs, & Cadby, 2005). Znanstveniki so v preteklih desetletjih veliko pozornosti namenili lokalni stabilnosti trupa, ki se v največji meri nanaša na stabilnost ledveno-medeničnega predela trupa (Willson, Dougherty, Ireland, & Davis, 2005). Stabilnost trupa je opredeljena kot sposobnost, da se trup po zunanji motnji povrne v začetno izhodišče oziroma, da lahko nadaljuje načrtovano gibanje in pri tem ne izgubi ravnotežja (Reeves, Narendra, & Cholewicki, 2007; B. Zazulak, Cholewicki, & Reeves, 2008). Iz tega sledi, da mora stabilizacijski sistem trupa zagotoviti stabilnost hrbtenice ob delovanju statičnih in dinamičnih sil na trup. Ko govorimo o stabilizacijskem sistemu trupa, imamo v mislih predvsem stabilizacijski sistem hrbtenice, ki tvori jedro trupa. Stabilizacijski sistem hrbtenice razdelimo v tri podsisteme: pasivni podsistem, aktivni

podsystem in nadzorni podsystem (Panjabi, 1992). Vzajemno delovanje vseh treh podsystemov je potrebno za učinkovito stabilizacijo hrbtenice in posledično trupa.

Pasivni podsystem sestavljajo sklepi, sklepne kapsule, vretenca, medvretenčne ploščice, ligamenti, pasivne mehanske lastnosti mišic in fascij. Pasivni sistem zagotavlja prenos sil med posameznimi segmenti in omejuje gibanje (Bergmark, 1989). Pasivni sistem deluje pri nevtralni drži kot receptor položaja in gibanja za nadzorni podsystem, medtem ko njegova stabilizacijska vloga pride do izraza proti končnemu obsegu giba. Strukture pasivnega podsystema oslabijo zaradi staranja ali bolezni. Če pride do oslabitve pasivnega podsystema, lahko to na drugi strani povzroči prilagoditve v aktivnem podsystemu.

Aktivni podsystem sestavljajo mišice in kite. Osnovni nalogi aktivnega podsystema sta vzdrževanje pokončnega položaja hrbtenice in varovanje ledvenega dela hrbtenice pred prekomernimi gibi. Aktivni podsystem se deli na lokalni in globalni sistem (Bergmark, 1989). Lokalni sistem zajema vse mišice, ki potekajo med medenico in prsnim košem in se pripenjajo na vretenca, ter zagotavlja mehansko togost hrbtenice. Globalni sistem sestavljajo mišice, ki povezujejo spodnje ude, zgornje ude, medenico, trup in hrbtenico. Mišice globalnega sistema opravljajo več nalog: zagotavljajo stabilnost trupa, generirajo navore in prenašajo obremenitve med spodnjimi udi, medenico, hrbtenico, trupom in zgornjimi udi. Globalni sistem preprečuje delovanje prevelikih sil na lokalni sistem. Aktivni sistem sprejema in izvaja ukaze nadzornega podsystema (Panjabi, 1992). Poškodbe aktivnega sistema (poškodbe, bolezni, staranje) lahko privedejo do zmanjšanja sposobnosti izvajanja teh ukazov.

Nadzorni podsystem sestavlja živčni podsystem, ki sprejema informacije iz senzoričnih organov. Na podlagi teh informacij določi potrebne zahteve za stabilnost hrbtenice in preko aktivnega podsystema, kateremu pošlje ukaze, doseže stabilnost hrbtenice (Panjabi, 1992). Nadzorni podsystem neprestano nadzoruje vse mišice in prilagaja njihovo napetost. Mišice morajo biti aktivirane ob pravem času in s pravo intenzivnostjo, da se zagotovi stabilnost hrbtenice, omogoči zahtevano gibanje in zaščiti hrbtenico pred poškodbami (Barr idr., 2005). Stabilnost hrbtenice je mogoča le ob usklajenem delovanju lokalnega in globalnega sistema mišic, zato ne moremo določiti mišic, ki več ali manj prispevajo k stabilnosti hrbtenice (Bergmark, 1989).

Proces uravnavanja mišične aktivnosti imenujemo živčno-mišično upravljanje (*angl: neuromuscular control*) (Cholewicki idr., 2002; Hammill, Beazell, & Hart, 2008; Zazulak, Hewett, Reeves, Goldberg, & Cholewicki, 2007). Ta je opredeljena kot zmožnost upravljanja mehanizmov, potrebnih za gibanje. Živčno-mišično upravljanje zajema sprejemanje informacij iz senzoričnih organov, njihovo obdelavo v centralnem žičnem sistemu (CŽS), integriranje

senzoričnih in motoričnih informacij ter oblikovanje gibalnih ukazov in posredovanje le-teh mišicam. Nemoteno živčno-mišično upravljanje je potrebno za usklajeno delovanje lokalnega in globalnega sistema mišic in posledično učinkovite stabilizacije hrbtenice. Prav tako živčno-mišično upravljanje usklajuje delovanje mišic ob pričakovanih in nepričakovanih motnjah stabilnosti (Barr idr., 2005).

Poškodba hrbta ali veliko ponavljajočih manjših preobremenitev povzroči spremembo informacij o lokalni in globalni stabilnosti ter posledično spremembo vzorcev mišične aktivacije (Hodges & Richardson, 1998; McGill, 2001; Panjabi, 2006). Spremenjeni vzorci mišične aktivacije pri preiskovancih brez predhodnih poškodb povečajo verjetnost poškodbe hrbta (Cholewicki idr., 2005). Vzrok za spremembe živčno-mišičnega upravljanja pa je lahko tudi bolečina (Hodges, Moseley, Gabrielsson, & Gandevia, 2003). Zelo pogosta bolečina v predelu hrbta je tako imenovana bolečina v spodnjem delu hrbta (BSH). Osebe z BSH so pogosto podvržene bolečini, ki se ponavlja periodično (Reeves idr., 2007). Za uspešno zdravljenje BSH je potrebno poznati mehanizme, ki se pogosto pojavljajo pri osebah z BSH. Dokazano je bilo, da je z ustrezno vadbo mogoče izboljšati spremenjene vzorce aktivacije posturalnih mišic in tako zmanjšati verjetnost poškodbe hrbta ali drugih sklepov (O'Sullivan, 2000; Pedersen, Essendrop, Skotte, Jørgensen, & Fallentin, 2004).

BSH je najpogostejši zdravstveni problem gibalnega aparata današnje populacije. Epidemiološke študije so pokazale, da od 70 do 85 % ljudi vsaj enkrat v življenju utрпи BSH. Pri 60 do 70 % teh primerov se omenjeni problemi ponavljajo večkrat (Frymoyer idr., 1983). Še posebej problematična je kronična BSH, ki je opredeljena z več kot tri mesece konstantne ali ponavljajoče BSH. Ta povzroči zmanjšanje kakovosti posameznikovega življenja in hkrati pomembno omejuje gibalne funkcije ter vsakodnevne aktivnosti. BSH je skupno drugi najpogostejši razlog izostanka z delovnega mesta pri delavno-aktivni populaciji (Drobnič-Kovač, 2002) in zato predstavlja velik socialno-ekonomski problem v večini razvitih držav in držav v razvoju. S tem povezani letni stroški v državah EU znašajo več milijard evrov (Lambeek idr., 2010).

Pri osebah z BSH je opaziti številne spremembe živčno-mišičnih funkcij trupa. Spremembe so na primer v zakasneli aktivaciji m. transversus abdominis, višjem pragu mišične aktivacije, povečanju smerne specifičnosti in fazičnosti mišične kontrakcije ter izgubi neodvisnega nadzora (Hodges & Richardson, 1997). Iztegovalke trupa postanejo šibke in hitreje utrudljive ter hkrati neuravnovešene z upogibalkami trupa (McGill, 2001). Značilno se poslabšajo kinestetično senzorične funkcije trupa (Leinonen idr., 2003). Leinonen in sodelavci (2003) so pri

osebah z BSH ugotovili poslabšanje splošnega telesnega ravnotežja in samodejnih funkcionalno-stabilizacijskih akcij trupa na pričakovane in nepričakovane mehanske motnje.

Spremembe v upravljanju gibanja vključujejo kompleksne spremembe načrtovanja upravljanja (Hodges idr., 2003). Za oceno posturalnega nadzora se pogosto uporablja spremljanje odzivov mišic trupa ob mehanski motnji z elektromiografijo (EMG). Motnja je lahko posledica hotenega giba ali zunanje sile.

O hotenem gibanju govorimo, kadar želimo izvesti načrtovano gibalno nalogo, kot je na primer dvig bremena, potiskanje bremena, met žoge, prijemanje kozarca in podobno. Vse te naloge zahtevajo predhodno stabilizacijo proksimalnih telesnih segmentov, kar se doseže z aktivnostjo posturalnih mišic. Pri teh nalogah velja zakonitost reakcije enake akciji preiskovanca (Bouisset & Do, 2008). To pomeni, da kadar pride na primer do premika uda, to posledično povzroči premikanje ostalega telesa v nasprotno smer. Za koordinirano delovanje udov in trupa poskrbi CŽS, ki predvidi posledice gibanja udov na trup in glede na predvidevanje načrtuje stabilizacijsko mišično aktivnost (Barr idr., 2005). Nekatere posturalne spremembe se zgodijo pred začetkom samega giba po načelu odprte zanke, kar imenujemo anticipacijske posturalne prilagoditve (APP). Pred začetkom giba se aktivirajo posturalne mišice in tako zagotovijo stabilnost sosednjih sklepov ob hkratnem ohranjanju projekcije težišča telesa znotraj podporne površine (Hodges & Richardson, 1997).

APP se ustvarjajo v višjih centrih CŽS (možgani, hrbtenjača) in niso refleksnega izvora (Cordo & Nashner, 1982; Latash, 2008). CŽS lahko v načrt povečanja posturalne stabilnosti glede na situacijo vključuje in izključuje segmente telesa in s tem zagotavlja najboljšo možno stabilnost telesa. CŽS pri tem upošteva tudi stabilnost predmeta, na katerega se telo naslanja. Kadar je stabilnost telesa zagotovljena, se to odraža v zmanjšanih APP. APP se dogajajo tudi pri nestabilnih pogojih, ko delujejo v smeri zmanjšanja motnje zaradi hotenega giba tako, da predhodno premaknejo telo v nasprotni smeri (De Wolf, Slijper, & Latash, 1998). Pri tem lahko pride do negativnih učinkov, kar povzroči še dodatno motnjo ravnotežja. Posledično je v takšnih primerih bolje, da CŽS zmanjša ali popolnoma izključi APP. Kadar so gibalne in posturalne mišice utrujene, pride do zgodnejših APP (Kanekar, Santos, & Aruin, 2008). Do zgodnejših APP v takšnem primeru pride zaradi potrebe po dosegi mišičnega impulza, ki je primerljiv z impulzom pri neutrujeni mišici (Strang & Berg, 2007). Pri osebah z BSH so se pokazale spremembe pri APP. Vzrok za to je lahko v spremembah načrtovanja gibanja ali v spremembah pri prenosu motoričnih ukazov v živčnem sistemu (Hodges, 2001). Raziskave so pokazale, da ponavljajoča BSH spremeni odzive mišic trupa (Hodges idr., 2003; Jacobs, Henry,

& Nagle, 2009), kar lahko privede do zmanjšane sposobnosti prilagajanja APP globalnih mišic trupa. Posledično lahko pride do povečane obremenitve pasivnih struktur hrbtenice na začetku hotenega gibanja in do nastanka BSH (Hammill idr., 2008).

Kadar pride do motnje zaradi zunanje sile, se telo odzove refleksno. Posturalni refleks je nezavedna mišična aktivnost, ki je posledica zunanje motnje (Latash, 2008). Odzivni časi mišic trupa na nenadno razbremenitev so daljši pri preiskovancih z BSH (Radebold, Cholewicki, Panjabi, & Patel, 2000). To je lahko pokazatelj sprememb v živčno-mišičnem upravljanju hrbtenice in posledično vzrok za BSH (Cholewicki idr., 2005; Hodges, van den Hoorn, Dawson, & Cholewicki, 2009). Osebe z BSH se na nenadno razbremenitev odzovejo z ohranitvijo aktivacije mišic ob hkratni aktivaciji mišic, ki delujejo v nasprotno smer, kar poveča motnjo stabilnosti. Pri osebah brez BSH pride v tem primeru do takojšnjega preklopa v aktivaciji mišic. Pri osebah s kronično BSH je bila pokazana večja togost hrbta in zmanjšana sposobnost dušenja gibanja (Hodges idr., 2009). To je razumljivo, saj pri zmanjšani sposobnosti dušenja lahko večja togost zmanjša največje premike.

Krčenje in raztezanje mišic je upravljano s strani CŽS, ki po živčnih vlaknih pošilja ukaze v mišico. Ukazi se prenašajo po živčnih vlaknih kot akcijski potenciali. Akcijski potencial je kratkotrajna električna napetost celične membrane zaradi depolarizacije, ki omogoča prenos informacij po živčnih celicah. Akcijski potenciali se preko motorične ploščice (mesto, kjer se motorični nevron stika z mišično celico) prenašajo na mišično celico. Zaradi stimulacije motorične ploščice se tvorijo akcijski potenciali (Kandel idr., 2000). Takšno električno aktivnost mišice lahko merimo z EMG. EMG je metoda za vrednotenje, snemanje in analizo električne aktivnosti skeletnih mišic (De Luca, 1985). EMG lahko uporabimo za ovrednotenje mišične funkcije s časovnimi in amplitudnimi parametri (Perry & Burnfield, 2010).

Električne signale, ki se tvorijo v mišicah, se lahko zajema na tri načine. Prvi način je merjenje električne napetosti posameznega mišičnega vlakna z iglo, ki se zabode v mišico. To metodo imenujemo igelna EMG. Zelo podoben je tudi drug način, ko se z debelejšo iglo meri električno napetost več mišičnih vlaken skupaj. Ta metoda se imenuje koncentrična EMG. Tretji način je neinvazivno merjenje električne napetosti na površini kože nad posamezno mišico, kar imenujemo površinska EMG. Za potrebe te naloge smo uporabljali samo površinsko EMG.

Pri površinski EMG se električno napetost meri z uporabo površinskih elektrod, pri čemer lahko uporabimo monopolarno ali bipolarno tehniko postavitve elektrod (De Luca, 1985). V EMG signalu na površini kože je seštetih več sto tokov iz mišičnih vlaken, ki jih aktivira posamezen akcijski potencial v motoričnem nevronu (Kandel idr., 2000). Amplituda EMG signala se

povečuje s številom rekrutiranih motoričnih enot in frekvenco njihove aktivacije (Merletti & Parker, 2004). EMG signal, ki ga zaznamo na površini kože, ima zelo kompleksno obliko, saj so v njem združene aktivnosti velikega števila mišičnih vlaken ene mišice, ki so časovno in prostorsko seštetje. Ker se napetostni količnik z oddaljenostjo od izvora zelo hitro manjša, bodo elektrode, postavljene več kot 2 do 3 mm od površine aktivnega mišičnega vlakna, zaznale zelo majno amplitudo signala. Ta amplituda signala je lahko celo manjša od zunanjih motenj (De Luca, 1985). Poleg električnega signala mišice EMG signal zelo pogosto vsebuje številne motnje, ki so naključne in v večini primerov neizogibne. Motnje, ki jih imenujemo tudi šum, so lahko notranje ali zunanje. Najpogostejši primeri motenj so: premikanje kože nad mišico, mehanski premik elektrode, premik kablov, električna napetost iz drugih mišic (npr. iz srca), motnja iz električnega omrežja in interferenca signalov iz okolice. Prisotnost motenj lahko povzroči napačno interpretacijo signalov (De Luca, Gilmore, Kuznetsov, & Roy, 2010). Nekaj tipov motenj se da preprečiti z dobro opremo in kakovostno izvedbo meritve, medtem ko se nekaterim motnjam ne moremo izogniti. Pri meritvah EMG signalov na trupu se večinoma uporablja bipolarna tehnika, ki meri napetostno razliko med dvema točkama (Cholewicki idr., 2005; Granata, Slota, & Bennett, 2004; Hodges & Richardson, 1997; Hodges idr., 2003; Radebold, Cholewicki, Polzhofer, & Greene, 2001).

Obstaja določena variabilnost aktivacije mišice med zaporednimi istovrstnimi meritvami, kar vpliva na ponovljivost meritev. Dodatne motnje iz okolice lahko to ponovljivost še poslabšajo, zato jih želimo popolnoma odstraniti ali v čim večji meri zmanjšati (Winter, 2009). Pred meritvami EMG je potrebno poskrbeti za dobro ozemljitev merjenca in prostora, v katerem se izvaja meritev, ter odstraniti nepotrebne električne naprave iz prostora. Zelo pomembna je tudi dobra priprava kože, saj se med kožo in elektrodo pojavi določena upornost, ki je nezaželena. Na upornost vpliva debelina posamezne plasti kože (predvsem maščobnega tkiva), poraščenost kože, plast odmrlih celic povrhnjice, mastnost kože in temperatura prevodnega gela (Hermens, Freriks, Disselhorst-Klug, & Rau, 2000). Priprava kože najpogosteje vključuje britje, razmaščevanje in abrazijo kože (De Luca, 1985; Merletti & Parker, 2004; Winter, 2009). Elektrode morajo biti dobro pritrjene na kožo, dobro prevodnost pa dosežemo s kontaktnim prevodnim sredstvom (gelom, kremo ali pasto). Zelo pomembna je pravilna postavitvev elektrod (Merletti & Parker, 2004). Elektrode je potrebno namestiti med motorično ploščico in kitno-mišični stik, saj postavitvev vsake od elektrod na drugi strani motorične ploščice zmanjša razliko v napetosti med elektrodama. Pomembna je tudi razdalja med elektrodama, pri čemer se povečanje razdalje odrazi v večji zastopanosti globljih motoričnih enot in s tem tudi amplitude EMG odziva. Pri povečevanju razdalje moramo biti pazljivi, saj se s tem poveča tudi

možnost zajema signalov iz sosednjih mišic (*angl. cross-talk*). Če ne gre za izolirano kontrakcijo mišice, kar velja za večino živčno-mišičnih funkcij trupa, zmanjšamo razdaljo med elektrodama in s tem dosežemo boljšo razmejenost zajetega signala ter se izognemo interferenci aktivnosti sosednjih mišic. To je predvsem pomembno pri računanju časovnih parametrov aktivacije posamičnih mišic.

Namestitev elektrod na mišice je pomembna zaradi primerljivosti rezultatov študij, pri katerih se uporablja EMG. Za ta namen obstaja standard SENIAM (*angl. surface electromyography for a non-invasive assessment of muscle*) za neinvazivno površinsko EMG mišic (Hermens idr., 2000), ki pa slabo pokriva ravno področje trupa. Različne raziskave s področja EMG meritev trupa navajajo različne postavitve elektrod (Hibbs, Thompson, French, Hodgson, & Spears, 2011; Masani idr., 2009; Radebold idr., 2001; Stokes, Gardner-Morse, Henry, & Badger, 2000). To lahko pripelje do neprimerljivih rezultatov in tudi nasprotujočih izsledkov (Merletti & Parker, 2004; Winter, 2009).

2 Predmet, problem, namen

EMG signal vsebuje električni signal, ki izvira iz ciljne mišice, in številne bolj ali manj predvidljive motnje iz okolice ter drugih električnih generatorjev v človeškem telesu. Nekaterim motnjam iz okolice se ne moremo izogniti. Zato se moramo obdelave EMG signala lotiti skrbno in na pravi način. V nasprotnem primeru lahko pridemo do rezultatov, ki ne odražajo realnega stanja. Ena pogostejših motenj, ki se pojavlja v EMG signalu, zajetem na mišicah človeškega trupa, je motnja, ki izvira iz aktivnosti srčne mišice (elektrokardiografska (EKG) motnja). EKG motnja lahko vpliva na določitev začetka mišične aktivacije v primeru, ko je začetek mišične aktivacije prepoznan kot začetek dogodka, ki je posledica aktivnosti srčne mišice. Obdelavo EMG signala lahko razdelimo po stopnjah, ki si morajo slediti v pravilnem vrstnem redu. Prva stopnja je predobdelava EMG signala, v kateri se odstranjuje motnje iz EMG signala. Druga stopnja je odstranjevanje EKG motnje iz EMG signala. Ta stopnja se izvede le takrat, ko je EKG motnja prisotna oziroma, ko obdelujemo EMG signale mišic, na katerih se pojavi EKG motnja. To stopnjo bi lahko vključili tudi v prvo stopnjo, vendar jo zaradi njenih posebnosti obravnavamo kot ločeno stopnjo. Tretja stopnja je iskanje začetka (*angl. onset*) in konca (*angl. offset*) mišične aktivacije v EMG signalu. V tej stopnji se poišče del EMG signala, ki vsebuje koristno informacijo. Četrta stopnja je izračun značilik, s katerimi ovrednotimo mišično aktivacijo oziroma preiskovani problem. Če preiskovanega problema ne moremo ovrednotiti iz posameznih značilik, potem uporabimo pristope, ki uporabljajo več značilik za pridobitev koristne informacije. Takšen primer je razvrstitev preiskovancev na zdrave in bolne, česar v splošnem ne moremo zanesljivo določiti samo na podlagi posamezne značilke. Pogosto tega ne moremo določiti niti z enim samim testom, ampak moramo uporabiti več testov, s katerimi dobimo kvalitetnejšo informacijo o preiskovanem problemu. V tej nalogi je bil uporabljen test, pri katerem smo spremljali samodejne posturalne akcije, ki so le eden od pomembnih vidikov živčno-mišičnega delovanja trupa. EMG signale smo zajemali iz mišic človeškega trupa pri izvajanju dveh nalog: APP na hotene gibe in posturalne reakcije na nenadne obremenitve (PRO). APP in PRO sta specifični in hkrati funkcionalno pomembni za trup ter zato tudi najpogosteje merjeni v splošnem.

Nekatere stopnje EMG obdelave ali posamezni deli stopenj se danes še vedno delajo ročno (npr. iskanje začetka mišične aktivacije, določanje vhodnih parametrov metod za obdelavo

EMG signala za posamezne primere posebej). Takšno delo temelji na dobrem poznavanju prednosti in omejitev trenutno priznanih metod. Zato je precej zamudno, omejeno na ročno obdelavo ekspertov z ustreznim znanjem in hkrati precej izpostavljeno napakam, ki so posledica človeške subjektivnosti in/ali padca koncentracije pri precej monotonem delu. Z avtomatsko obdelavo EMG signalov bi zagotovili objektivno analizo podatkov, prihranili veliko časa in jo za uporabnika zelo poenostavili. Hkrati bi avtomatska obdelava EMG signalov brez posredovanja uporabnika omogočala obdelavo velikih količin podatkov brez pretiranega napora.

Predmet doktorskega dela je obdelava EMG signalov, zajetih pri meritvah APP in PRO. Problem je avtomatska obdelava EMG signalov, zajetih pri meritvah APP in PRO brez posredovanja uporabnika. Trenutno znane metode za obdelavo EMG signalov ne omogočajo avtomatske obdelave, ravno nasprotno, potrebno je veliko ročnega dela in ekspertno znanje. Zato je namen naloge razviti metode, ki bodo omogočale avtomatsko obdelavo EMG signalov, zajetih pri meritvah APP in PRO brez posredovanja uporabnika.

3 Ozadje

V tem razdelku si bomo pogledali metode za obdelavo EMG signalov, ki so bile do sedaj predlagane v literaturi. Najprej bomo na kratko povzeli dve metodi (diskretna valčna transformacija in empirična razgradnja), ki sta bili večkrat uporabljeni kot osnova različnih pristopov za obdelavo EMG signalov v različnih stopnjah obdelave. Nato sledi podroben pregled do sedaj uporabljenih metod po stopnjah obdelave EMG signala: predobdelava EMG signala, odstranjevanje EKG motnje iz EMG signala, iskanje začetka in konca mišične aktivacije ter izračun značilik in klasifikacija.

Valčna transformacija (Akansu & Haddad, 1992) je zelo dobro uveljavljena metoda na področju obdelovanja signalov. Poznamo diskretno valčno transformacijo (DVT) in zvezno valčno transformacijo. Tukaj bomo povzeli samo DVT, saj je osnova za več različnih metod, ki se uporabljajo pri obdelavi EMG signalov. DVT najprej razstavi signal z valčnimi funkcijami (valčki), ki jih dobimo s skaliranjem in translacijo izhodiščne valčne funkcije. Obstajajo različne izhodiščne valčne funkcije, ki se razlikujejo po obliki in lastnostih (Haar, Daubechies,...). DVT signala se izračuna z zaporedjem filtrov, skozi katere gre signal. Zaporedje filtrov je sestavljeno iz nivojev, kjer se na vsakem nivoju uporabi visoko prepustni filter za izračun visokih frekvenčnih komponent in nizko prepustni filter za izračun nizko frekvenčnih komponent. Oba filtra morata biti povezana med seboj tako, da se frekvenčno območje razpolovi. To pomeni, da se na prvem nivoju osnovni signal (katerega največja frekvenca je f_m) razstavi na dva signala tako, da prvi signal vsebuje frekvence od $f_m/2$ do f_m , drugi signal pa frekvence od 0 do $f_m/2$. Na drugem nivoju in vsakem naslednjem nivoju se razstavi signal, ki vsebuje nizko frekvenčne komponente. Število nivojev določi uporabnik. Poznamo tudi valčno paketno transformacijo, ki je identična DVT, s to razliko, da se na isti način kot nizko frekvenčna komponenta razstavi tudi visoko frekvenčna (Akansu & Haddad, 1992).

Empirična razgradnja (*angl. empirical mode decomposition* (EMD)) je adaptivna metoda, ki izvorni signal razstavi na komponente (*angl. intrinsic mode functions* (IMF)). IMF je opredeljena kot funkcija, ki izpolnjuje dva pogoja: (1) število ekstremov in število prečkanj vrednosti nič mora biti ali enako ali se razlikovati za največ ena, in (2) povprečna ovojnica, ki se izračuna kot razlika med zgornjo (lokalni maksimumi) in spodnjo (lokalni minimumi) ovojnico, je enaka nič

za vsako časovno točko signala. V nadaljevanju je opisan postopek računanja IMF-jev (Andrade, Nasuto, Kyberd, Sweeney-Reed, & Van Kanijn, 2006; Huang idr., 1998).

- (1) V spremenljivko x vpišemo izvorni signal in spremenljivko k , ki je trenutno število IMF-jev, nastavimo na 0.
- (2) Z interpolacijo z zlepci na lokalnih maksimumih/minimumih izračunamo zgornjo/spodnjo ovojnico.
- (3) Povprečno ovojnico m izračunamo kot aritmetično sredino med zgornjo in spodnjo ovojnico.
- (4) Kandidat h za IMF je razlika med x in m .
- (5) Če h ne zadosti pogojem za IMF, je $x = h$ in skočimo na korak 2. Če h je IMF, potem skočimo na korak 6.
- (6) Če h je IMF, se shrani kot c_k , kjer je k k-ta komponenta.
- (7) Izračunamo srednjo kvadratno napako med dvema zaporednima IMF-jema (c_{k-1} in c_k), ki jo primerjamo z ustavitvenim kriterijem (običajno je to zelo majhna vrednost, tj. 10^{-5}).
- (8) Če ustavitven kriterij ni dosežen, izračunamo parcialni ostanek r_k kot razliko med predhodnim parcialnim ostankom r_{k-1} in c_k . r_k zapišemo v x in skočimo na korak 2.
- (9) Če je ustavitven kriterij dosežen, ustavimo postopek in izračunamo končni ostanek r_{final} kot razliko med izvornim signalom in vsoto vseh IMF-jev.

Prednosti EMD analize sta adaptivna dekompozicija vhodnega signala in nepotrebnost po predhodnega poznavanja signala. Na drugi strani so slabosti pomanjkanje matematične teorije, časovno potratno računanje IMF-jev in problem mešanja načinov (*angl. mode mixing problem*), ki je posledica nestalnosti signala. Ta povzroči, da ena IMF vsebuje podatke z zelo različnimi amplitudami in frekvencami (Wu & Huang, 2009). Temu problemu se je mogoče delno izogniti z večstopenjsko EMD (*angl. ensemble empirical mode decomposition* (EEMD)) (Wu & Huang, 2009).

3.1 Predobdelava EMG signala

EMG signali lahko vsebujejo poleg koristnih informacij tudi veliko motenj, ki jih imenujemo šum. Šum je lahko različnega izvora, saj EMG elektrode merijo električno napetost in zato poleg električne napetosti v mišici zaznajo tudi druge električne napetosti iz okolice (bodisi iz

samega telesa merjenca ali iz prostora, v katerem se nahajamo). Pogosti izvori šuma so: mehanski premik elektrode ali kabla, interferenca napajalnega izmeničnega toka, EMG signal iz sosednjih mišic, potencial napetosti srčne mišice. Velik del šuma je mogoče odstraniti s tipičnimi metodami filtriranja (npr. pasovno prepustni filter), vendar je s temi metodami težko odstraniti interferenco naključnega šuma, ki pade v EMG frekvenčni spekter (Phinyomark, Limsakul, & Phukpattaranont, 2009). Tipično se za predstavitev naključnega šuma v EMG signalu uporablja beli Gaussov šum (*angl. white Gaussian noise*). Za odstranjevanje belega Gaussovega šuma je bilo predlaganih več metod, od katerih so bile različne metode odstranjevanja šuma z valčno analizo (*angl. wavelet denoising*) najpogosteje uporabljene (Phinyomark idr., 2009; Staude, 2001). Belega Gaussovega šuma ni mogoče popolnoma odstraniti, hkrati pa se s predlaganimi metodami lahko odstrani tudi pomemben del EMG signala.

Pasovno prepustni filtri so dobro poznan in uveljavljen pristop v obdelavi signalov. Namenjeni so odstranjevanju določenega dela frekvenčnega spektra iz signala. Ločimo štiri tipe pasovno prepustnih filtrov glede na frekvenčno prepustnost: nizko prepustni (prepušča nizke frekvence), visoko prepustni (prepušča visoke frekvence), pasovno prepustni (prepušča določen pas frekvenc) in pasovno zaporni (prepušča frekvence izven pasu). Idealen filter ohranja celoten frekvenčni spekter v prepustnem pasu, medtem ko odstrani celoten frekvenčni spekter v neprepustnem pasu. Vendar v praksi temu ni tako, kar pomeni, da obstaja območje med prepustnim in neprepustnim pasom (prehod), kjer so frekvence delno odstranjene. Prehod lahko uravnavamo z izbiro družine in stopnje filtra. Poznamo različne družine filtrov (Butterworth, Chebyshev, Bessel, Cauer), ki se razlikujejo v širini prehoda in v zanesljivosti prepuščanja frekvenc v prepustnem pasu ter odstranjevanja frekvenc v neprepustnem pasu. Velja, da filter z ožjim prehodom slabše prepušča/odstranjuje frekvence v prepustnem/neprepustnem pasu in obratno. Z večanjem stopnje filtra se prehod oži in hkrati zmanjšuje zanesljivost prepuščanja/odstranjevanja frekvence v prepustnem/neprepustnem pasu. Zavedati se moramo tudi, da pri filtriranju signala pride do določenega zamika signala v fazi (v času). To je pomembno takrat, ko uporabljamo časovne parametre dveh signalov, ki sta bila filtrirana z različnimi filtri (tipi, družinami, stopnjami). Problem faznega zamika lahko rešimo tako, da signal v prvem koraku filtriramo v eni smeri in v drugem koraku v nasprotni smeri. S pasovno prepustnimi filtri je mogoče odstraniti velik del šuma v EMG signalu, vendar je z njimi težko odstraniti interferenco naključnega šuma (Phinyomark idr., 2009).

Z odstranjevanjem šuma iz EMG signalov z uporabo DVT se je v preteklosti ukvarjalo že veliko raziskovalcev (Hussain, Reaz, Mohd-Yasin, & Ibrahimy, 2009; Phinyomark, Limsakul, &

Phukpattaranont, 2009a, 2009b; Staude, 2001). Odstranjevanje šuma iz EMG signala poteka v treh korakih (Phinyomark idr., 2009b): dekompozicija signala, odstranjevanje šuma iz dobljenih komponent in rekonstrukcija signala. Pri dekompoziciji najprej izberemo primerno izvorno valčno funkcijo in število nivojev ter nato izvedemo DVT. V drugem koraku se pridobljene komponente vsakega nivoja filtrirajo na podlagi izbrane pragovne funkcije. Pragovna funkcija nastavi vse vrednosti pod določenim pragom na nič in ohrani vse ostale vrednosti. V literaturi je bilo predlaganih več različnih pragovnih funkcij (Hussain idr., 2009; Phinyomark idr., 2009a, 2009sb). Očiščene komponente se z inverzno DVT rekonstruirajo v signal, ki je očiščen šuma. Phinyomark in sodelavci (2009b) so za odstranjevanje belega Gaussovega šuma predlagali uporabo DVT z izhodiščno valčno funkcijo Daubechies (db2), številom nivojev 4 in mehko pragovno funkcijo, pri kateri se prag določi z univerzalno pragovno metodo. Mehka pragovna funkcija nastavi vse vrednosti pod določenim pragom na nič in »skrči« vse ostale vrednosti proti nič. Avtorji so do tega zaključka prišli na podlagi analize, v kateri so uporabili vse kombinacije 53 različnih izhodiščnih valčnih funkcij, štirih metod za določitev praga, štirih pragovnih funkcij in števila nivojev med 1 in 8. Prednost odstranjevanja šuma z valčno analizo je neodvisno filtriranje posameznih komponent signala, medtem ko je slabost vnaprejšnja izbira izhodiščne valčne funkcije, kar lahko vpliva na rezultat. V literaturi je bila za odstranjevanje šuma uporabljena tudi paketna valčna transformacija, ki je po uspešnosti odstranjevanja šuma iz EMG signala primerljiva z DVT (Phinyomark idr., 2009b).

Postopek odstranjevanja šuma z EMD je enak postopku odstranjevanja šuma z DVT (Andrade idr., 2006; Zhang & Zhou, 2013) in poteka v treh korakih: dekompozicija signala na IMF-je, odstranjevanje šuma iz dobljenih IMF-jev s pragovno funkcijo in rekonstrukcija signala (Andrade idr., 2006). Pri dekompoziciji se signal razstavi na IMF-je, katerih število je vnaprej neznano in je pogojeno z EMD algoritmom. IMF-ji se v drugem koraku filtrirajo z mehko pragovno funkcijo. Prag se določi kot SD na oknu, ki ga določi uporabnik na izvornem signalu kot področje, kjer je prisoten samo šum (v primeru EMG signala to okno ne sme vsebovati fiziološkega signala). Prag se izračuna za vsako IMF posebej. V tretjem koraku se filtriran izvorni signal izračuna kot linearna vsota vseh filtriranih IMF-jev. Slabost tega pristopa je, da mora uporabnik določiti okno šuma na izvornem signalu. Andrade in sodelavci (2006) so poročali boljše rezultate pri odstranjevanju šuma z EMD v primerjavi z DVT metodo, opisano v prejšnjem odstavku (Daubechy valčki – db2, db3 in db4). Zhang in Zhou (2013) sta primerjala EEMD in EMD pristop za odstranjevanje šuma in ugotovila, da ima EEMD prednost pred EMD pristopom še posebej pri signalih z nizkim razmerjem med signalom in šumom.

3.2 Odstranjevanje EKG motnje iz EMG signala

Poseben problem pri obdelavah EMG signalov mišic trupa so EKG motnje. Gre za motnje, ki so posledica delovanja srca in so zato zelo izrazite pri nekaterih mišicah trupa, ki se nahajajo blizu srca. EKG motnja (EKG artefakt) je problematična iz dveh razlogov: (1) je vsebovana v aktivnem delu (kjer je prisotna mišična aktivacija) EMG signala, kar vpliva na izračun značilik; ali (2) je vsebovana v neaktivnem delu (kjer ni mišične aktivacije) EMG signala, kar predstavlja problem pri zaznavanju dogodkov in tudi pri izračunu značilik neaktivnega dela signala. Frekvenčna spektra EKG (med 1 in 75 Hz (Zhan, Yeung, & Yang, 2010)) in EMG (med 0 in 500 (De Luca, 1997)) signala se delno prekrivata, zato je odstranjevanje EKG motnje še posebej zahteven problem (Christov & Daskalov, 1999). Hu in sodelavci (2009) so pokazali, da ima EKG artefakt statistično značilen učinek na EMG značilke mišic hrbta in na njihovo občutljivost pri vrednotenju BSH.

V preteklosti je bilo predlaganih več metod za odstranjevanje EKG artefakta iz EMG signala (Drake & Callaghan, 2006; Hof, 2009; Lee & Lee, 2013; Lu idr., 2009; Taelman, Mijovic, & Huffel, 2011; von Tscherner, Eskofier, & Federolf, 2011; Zhan idr., 2010; Zhou, Lowery, Weir, & Kuiken, 2005; Zivanovic & González-Izal, 2012). Edina popolnoma zanesljiva metoda je, da EMG merimo takrat, ko vemo, da ne bo EKG artefakta. Vendar ima ta metoda več slabosti: potrebna je dodatna strojna in programska oprema za realno-časovno zaznavo EKG artefakta, EMG lahko zanesljivo merimo le med dvema EKG artefaktoma (to časovno okno je približno slabo sekundo v pogojih nizkega fiziološkega napora) in ne moremo obdelati že obstoječih meritev, ki vsebujejo EKG motnjo. Ostale metode poskušajo odstraniti EKG artefakt tako, da analizirajo posamezen EMG signal ali več EMG signalov hkrati in izluščijo EKG artefakte iz EMG signala. Večina teh pristopov temelji na uporabi filtriranja frekvenčnega spektra ali neke izvedenke prilagodljivega filtriranja.

Zelo enostavna metoda za odstranjevanje EKG artefakta je visoko prepustni filter. Njegovo uporabo kot najprimernejše metode za odstranjevanje EKG artefaktov (Butterworth visoko prepustni filter s prepustnim pasom nad 30 Hz) sta predlagala Drake in Callaghan (2006), ki sta v svoji študiji primerjala več različnih pristopov. Vendar se moramo zavedati tudi omejitve te metode zaradi prej omenjenega prekrivanja frekvenčnih spektrov EKG in EMG signala ter posledično nepotrebne izgube dela EMG signala ali nepopolne odstranitve EKG signala. Naslednja preprosta metoda za odstranjevanje EKG artefakta je izrezovanje, ki iz EMG signala v časovni domeni izreže del, kjer je EKG motnja (Bartolo, Roberts, Dzwonczyk, & Goldman, 1996;

Zhou idr., 2005). Metoda temelji na hkratnem zajemanju EMG in referenčnega EKG signala. Na referenčnem EKG signalu se poišče okna, kjer so prisotni EKG artefakti, in se nato del EMG signala v isto ležečih oknih nadomesti z delom takoj pred oknom. Potreba po dodatnem zajemu referenčnega EKG signala in nezmožnost obdelave že zajetih meritev sta slabosti te metode. Pogosto uporabljena metoda za odstranjevanje EKG artefakta je tudi odštevanje predloge (*angl. template subtraction*) (Bartolo idr., 1996; Hof, 2009; Zhou idr., 2005). Najprej se določi predloga iz več »čistih« EKG artefaktov, ki se nato uporabi za detekcijo vrhov EKG artefaktov v obdelovanem signalu z računanjem korelacije med obdelovanim signalom in predlogo. Prepoznani EKG artefakti se odstranijo z odštevanjem predloge (poravnane na vrh EKG artefakta) od obdelovanega signala. Prilagodljivo filtriranje (*angl. adaptive filtering*) je metoda, ki uporablja referenčni EKG signal, katerega zajamemo sočasno z EMG signalom (Lu idr., 2009; Zhou idr., 2005). Metoda temelji na predpostavki, da je onesnažen EMG signal kombinacija čistega EMG signala in EKG motnje (EKG komponente). EKG komponenta se izračuna z modeliranjem referenčnega EKG signala z digitalnim filtrom s končnim impulznim odzivom in uporabo algoritma rekurzivnih najmanjših kvadratov za adaptivni izračun uteži. Na koncu se od onesnaženega EMG signala odšteje EKG komponenta, da dobimo očiščen EMG signal. Metoda se ni pokazala za zanesljivo, saj ni zmožna popolnoma odstraniti EKG artefaktov iz EMG signala (Zhou idr., 2005).

Skupina naprednejših metod za odstranjevanje EKG motnje temelji na uporabi valčne analize in prilagodljivega odstranjevanja delov EMG signala v časovno-frekvenčni domeni (von Tscharner idr., 2011; Zhan idr., 2010). Postopek je podoben postopku filtriranja EMG signala z DVT in sestoji iz dekompozicije EMG signala z DVT, odstranjevanja EKG artefaktov iz dobljenih komponent in rekonstrukcije signala. Postopka se razlikujeta le v drugem koraku, kjer se lahko uporabi različne pristope za odstranjevanje motenj. Nelinearna pragovna funkcija se uporabi za filtriranje dobljenih valčnih komponent tako, da se koeficienti, večji od praga, nastavijo na 0. Prag se določi adaptivno glede na koeficiente, ki očitno odstopajo od okolice (visoki koeficienti) (Zhan idr., 2010). V večini primerov se je metoda izkazala za učinkovito pri odstranjevanju EKG motnje iz EMG signala (von Tscharner idr., 2011), vendar so bili tudi primeri, pri katerih ni delovala dobro (Zhou idr., 2005).

V zadnjih letih je bila za odstranjevanje EKG motnje velikokrat uporabljena metoda neodvisnih komponent (*angl. independent component analysis (ICA)*) (Mak, Hu, & Luk, 2010; Willigenburg, Daffertshofer, Kingma, & van Dieën, 2012). ICA je dobro uveljavljena metoda za ločevanje statistično neodvisnih vzorcev iz seta njihovih linearnih kombinacij (Comon, 1994). Metoda ne uporablja nobenih predpostavk glede mešanja procesov in potrebuje zelo malo podatkov o

izvorih, da jih lahko ustrezno loči. ICA poskuša ločiti multi-variatni signal v neodvisne ne-Gaussove signale. Vhod v ICA algoritem je množica signalov, iz katere algoritem določi neodvisne izvore. Število nelinearnih izvorov lahko določi uporabnik ali pa je enako številu vhodnih signalov. ICA metoda za odstranjevanje EKG motnje temelji na predpostavki, da en EMG signal vsebuje kombinacijo več izvorov (EMG signali sosednjih mišic vključno z EKG). Metoda deluje tako, da za vhodne podatke vzame več EMG signalov in iz njih izlušči EMG signale za posamezne izvore, od katerih je eden EKG signal. Mak in sodelavci (2010) so v svoji raziskavi poročali zelo uspešno odstranjevanje EKG artefaktov iz EMG signalov (zaznava EKG artefaktov s 100 % občutljivostjo in 99 % specifičnostjo), vendar je potrebno tukaj poudariti, da so bili rezultati pridobljeni na umetno ustvarjeni množici signalov (realnim EMG signalom je bil prištet realen EKG signal). V primeru, da neodvisnost EMG in EKG signala ni zagotovljena, ima metoda omejeno uspešnost zaradi ICA definicije, ki predpostavlja neodvisne izvore (Willigenburg idr., 2012). Pomanjkljivosti metode sta tudi neprimernost za obdelavo samo enega EMG signala in dejstvo, da moramo v najprej vedeti, koliko izvorov imamo.

Nadgradnja ICA metode za odstranjevanje EKG artefaktov, ki je primerna za obdelavo posameznega EMG signala naenkrat, je uporaba ICA metode v kombinaciji z EMD ali DVT (Taelman, Mijovic, & Van Huffel, 2011). EMD in DVT razstavita EMG signal na končno število komponent. Pri DVT število komponent določi uporabnik, medtem ko pri EMD število komponent določi sam algoritem. Te komponente potem uporabi ICA za določitev neodvisnih izvorov (število izvorov določi uporabnik). Iz izvorov se izloči tiste, ki vsebujejo EKG motnjo, ter se preostale izvore uporabi za rekonstrukcijo EMG signala. Taelman in sodelavci (2011) so poročali večjo uspešnost EMD-ICA pristopa za odstranjevanje EKG motnje v primerjavi z DVT-ICA pristopom. Iz predhodnih pilotskih študij vemo, da tudi ta metoda ni zanesljiva. Prvi problem je v določanju števila izvorov, ker ga ne moremo poznati vnaprej, saj ne moremo vedeti, iz koliko izvorov je sestavljen EMG signal. Drug problem pa izhaja iz slabega ločevanja EKG izvora od ostalih izvorov in s tem nezmožnost ali poslabšano odstranjevanje EKG motnje.

Za odstranjevanje EKG artefaktov iz EMG signala je bila uporabljena tudi kombinacija nelinearno skaliranih valčkov in ICA metode (von Tscharner idr., 2011). Simetrični in asimetrični (realni in imaginarni) valčki (Barandun, von Tscharner, Meuli-Simmen, Bowen, & Valderrabano, 2009; von Tscharner, 2000) so bili uporabljeni za dekompozicijo EMG signala v časovno-frekvenčnem prostoru. Metoda v prvem koraku izračuna jakostni vzorec, ki je pridobljen iz vsote kvadratov simetričnih in asimetričnih delov in vsebuje mešanico EMG in EKG moči. V drugem koraku razreže jakostni vzorec na dele, ki večinoma vsebujejo moč iz EKG signala, in na dele, ki večinoma vsebujejo moč iz EMG signala. Srednja valčna jakostna spektra od EKG in

EMG spektra sta uporabljena kot vhoda za ICA metodo. ICA metoda izloči izvorna vektorja za EKG in EMG spekter. Izvorni vektor EKG spektra se uporabi za izločitev moči EKG signala iz jakostnega vzorca. V tretjem koraku se moč EKG signala odšteje od jakostnega vzorca, tako da ostane samo moč EMG signala. Razmerje moči EKG vzorca ter EKG in EMG vzorca skupaj se uporabi za določitev uteži valčne transformacije onesnaženega EMG vzorca. Očiščen EMG signal se izračuna z inverzno valčno transformacijo na uteženem EMG vzorcu. Primerjava uspešnosti odstranjevanja EKG artefaktov te metode z metodo visoko prepustnega filtra (Butterworth s prepustnim pasom nad 30 Hz) je pokazala boljše ohranjanje frekvenčnega spektra EMG signala pod 50 Hz, medtem ko pri frekvencah, večjih od 50 Hz, ni bilo razlike. Slabost metode je neprimernost za analizo signalov, kjer je ali EKG ali EMG signal zelo šibek (von Tscherner idr., 2011).

3.3 Iskanje začetka in konca mišične aktivacije

Zelo pogosto moramo pri obdelavi EMG signalov določiti začetek in konec mišične aktivacije (*angl. onset and offset detection*). Aktivacija mišice v EMG signalu izgleda vizualno kot povečanje amplitude alternirajočega signala. Začetek mišične aktivacije lahko opišemo kot začetek povečane amplitude v primerjavi z neaktivnim delom (del, kjer je mišica razbremenjena). Iskanje začetka in konca aktivacije je velikokrat osnova za nadaljnje vrednotenje EMG signalov. Zelo pogosto se uporablja za izračun elektro-mehanske zakasnitve (zakasnitev od začetka aktivacije mišice do mehanskega začetka giba) in za izračun raznih značilnosti v delu EMG signala, kjer je mišica aktivna. Iskanje začetka in konca mišične aktivacije lahko razdelimo na reševanje dveh problemov. Prvi problem predstavlja iskanje dogodkov mišične aktivacije. Na EMG signalu poiščemo vse dogodke, ko je mišica aktivna. Drug problem je iskanje začetka enega dogodka, ko moramo določiti začetek in konec mišične aktivacije čimbolj natančno. V tej nalogi smo se omejili na iskanje začetka enega dogodka, saj smo zaradi narave izvajanja gibalnih/testnih nalog pri meritvah lahko zanesljivo določili interval, na katerem je prišlo do mišične aktivacije. Ravno tako so vse predstavljene metode v tem razdelku namenjene izključno iskanju začetka enega dogodka mišične aktivacije.

V literaturi je bilo za iskanje začetka in konca mišične aktivacije predlaganih več metod. Večina metod je primarno namenjena iskanju začetka, saj je ta bolj pomemben in večkrat uporabljan za nadaljnje analize, kot pa konec. Večino metod lahko z določenimi prilagoditvami uporabljamo tudi za iskanje konca. Metode za iskanje začetka mišične aktivacije lahko v

grobem razdelimo v tri skupine: (1) metode, ki temeljijo na izbiri praga; (2) metode, ki temeljijo na statistično optimalni odločitvi; (3) ostale metode.

Najpogosteje uporabljene metode, ki temeljijo na izbiri praga, so: Hodges in Bui, Bonato, Lidiirth in Abbink (Staude, Flachenecker, Daumer, & Wolf, 2001). Najpreprostejša metoda in osnova tudi za ostale metode je metoda Hodges in Bui (Hodges & Bui, 1996). Metoda EMG signal najprej filtrira z nizko prepustnim filtrom ter ga nato še absolutira. Za iskanje začetka mišične aktivacije uporablja drseče okno s fiksno širino. Drseče okno je okno, ki se pomika po signalu z določenim časovnim korakom. V prvem koraku je okno popolnoma na neaktivnem delu EMG signala, kjer se izračunata povprečna vrednost in standardni odklon (*angl. standard deviation* (SD)). Nato začne okno drseti po EMG signalu in v vsakem koraku izračuna odstopanje povprečne vrednosti na oknu glede na prvi korak. Če je to odstopanje večje kot h SD-jev (h določi uporabnik), se začetna točka okna uporabi za začetek mišične aktivacije. Nadgradnja metode Hodges and Bui je metoda Lidiirth (Lidiirth, 1986). Metoda deluje po enakem načelu kot metoda Hodges and Bui, le da je pogoj za ustavitev algoritma in s tem določitev začetka mišične aktivacije drugačen: odstopanje od povprečne vrednosti za h vsaj za čas t_1 in znotraj časovnega okna t_1 lahko odstopanje pade pod prag h , vendar ne dlje kot za čas t_2 (t_1 in t_2 določi uporabnik). Metoda Abbink (Abbink, van der Bilt, & van der Glas, 1998) v osnovi uporablja metodo Hodges and Bui, vendar je pogoj za določitev začetne točke mišične aktivacije drugačen. Ta je določen kot največja razlika med časovnima oknoma dolžine t_3 neposredno pred in po potencialni točki začetka mišične aktivacije. Največja razlika se izračuna kot vsota števila vrednosti, ki so pod pragom k za okno pred in nad pragom k za okno po potencialni točki začetka mišične aktivacije (t_3 in k določi uporabnik). Še ena preprosta metoda je Bonato (Bonato, D'Alessio, & Knaflitz, 1998). Metoda podobno kot metoda Hodges and Bui izračuna začetno povprečno vrednost in SD na neaktivnem delu EMG signala, ki ju uporabi za iskanje začetka mišične aktivacije. Nato računa vsote dveh zaporednih vrednosti EMG signala in preverja, ali presežejo prag h . Začetek mišične aktivacije se določi v točki, ko vsaj n od m zaporednih vsot preseže prag h in to traja vsaj za čas t_1 (n in m določi uporabnik).

Med metodami za iskanje začetka mišične aktivacije, ki temeljijo na statistično optimalni odločitvi, se v literaturi najpogosteje omenjajo naslednje tri: metoda optimalne cenilke (*angl. optimal estimator*) in detektor na podlagi aproksimiranega generaliziranega razmerja verjetnosti (*angl. Approximated generalized likelihood-ratio detector* (AGLR)), ki ima dve različici, imenovani korak (AGLRstep) in rampa (AGLRramp). Metoda optimalne cenilke (Staude idr., 2001) v osnovi primerja razmerje logaritemske verjetnosti med dvema porazdelitvama pred in po potencialnem začetku mišične aktivacije. Ker točka začetka mišične aktivacije ni

znana, se uporabi ocena največje verjetnosti, ki je največja vrednost testne funkcije na testiranem časovnem oknu. Obe izvedenki AGLR metode imata isto osnovo (Santos idr., 2011; Staude & Wolf, 1999; Staude, 2001; Staude idr., 2001), ki je podobna metodi optimalne cenilke, le da namesto ocene največje verjetnosti uporabita aproksimirano generalizacijo razmerja verjetnosti. V prvem koraku se uporabi drseče okno s fiksno širino za iskanje približnega začetka mišične aktivacije (in je hkrati zanesljivo znotraj dogodka). Nato se v drugem koraku poišče točen začetek mišične aktivacije tako, da se z variabilnim oknom poišče točko, kjer je razmerje logaritemske verjetnosti pred in po točki največje. AGLRstep izvedenka predvideva spremembo amplitude EMG signala v obliki stopnice, medtem ko AGLRramp izvedenka predvideva spremembo amplitude v obliki rampe. Xu in sodelavci (2013) so predlagali nadgradnjo AGLR metode s prilagodljivim pragom, ki se določi na podlagi razmerja med signalom (kjer je mišica aktivna) in šumom (kjer je mišica neaktivna).

Metoda integriranega profila (*angl. integrated profile*) (Allison, 2003; Santello & McDonagh, 1998) uporablja za zaznavanje začetka aktivacije integriran profil absolutiranega EMG signala, ki se izračuna kot integral do vsake časovne točke EMG signala. Integriran profil se nato časovno in amplitudno normalizira (največji čas in največja amplituda sta enaka 1). Tako dobljen integriran profil se primerja z referenčno linijo, katere naklon je enak 1. Začetek mišične aktivacije se določi v točki, kjer je odstopanje med integriranim profilom in referenčno linijo največje. Metoda je nagnjena k napačnim prepoznavam začetka mišične aktivacije v primerih, ko šibkejši sledi močnejša mišična aktivacija (Allison, 2003; Santello & McDonagh, 1998).

Lee in sodelavci (2009) so predstavili metodo za iskanje začetka mišične aktivacije z uporabo EMD. V prvem koraku se naredi EMD, ki določi IMF-je. Potem se za vsako IMF izračuna sintetična funkcija $s_i = X - \sum_{k=i}^i IMF_k$, kjer je X EMG signal in i zaporedni indeks IMF-ja. Za vsako sintetično funkcijo se izračunata SD in povprečna vrednost v delu, ko je mišica neaktivna (okno za izračun določi uporabnik). Z uporabo praga ($5 * standardna\ deviacija + srednja\ vrednost$) se na sintetični funkciji z najmanjšim SD določi začetek mišične aktivacije. Avtorji so primerjali metodo EMD z metodo integriranega profila in pokazali, da je EMD metoda boljša za iskanje začetka mišične aktivacije.

Metoda vzorčne entropije za zaznavanje začetka mišične aktivacije je bila razvita z namenom, da se lahko uporablja tudi na EMG signalu, ki vsebuje EKG artefakte (Zhou & Zhang, 2014). Ideja temelji na dejstvu, da EMG in EKG signala izvirata iz dveh različnih dinamičnih sistemov. Z metodo vzorčne entropije se poudari EMG aktivnost in zatire EKG artefakte. Za izračun vzorčne

entropije se uporabi drseče okno s fiksno širino. Nato se na tako obdelanem EMG signalu določi začetek mišične aktivacije z uporabo navadnega praga. Avtorja sta metodo testirala na naboru drsečih oken različnih širin in pokazala, da je najbolj primerna uporaba okna dolžine 128 ms. Z uporabo tega okna se EKG artefakti zatrejo v tolikšni meri, da je iskanje začetka mišične aktivacije z navadnim pragom zanesljivo. Metoda zaradi računanja vzorčne entropije na drsečem oknu popači dejanski začetek mišične aktivacije (podobno kot filter tekoče aritmetične sredine za glajenje signala), kar pomeni, da bo zmeraj prisotna določena napaka (Zhou & Zhang, 2014).

3.4 Izračun značilnik in klasifikacija

Pomemben del obdelave EMG signala je izračun značilnik, na podlagi katerih ovrednotimo preiskovan problem. Značilke se lahko uporabljajo tudi v postopku klasifikacije, ko jih uporabimo za vhodni vektor, ki vstopa v klasifikator. Klasifikator na podlagi »znanja«, specifičnega za preiskovan problem, ustrezno klasificira vhodni vektor. Značilke, ki se uporabljajo za vrednotenje EMG signala, so v literaturi razdeljene v tri skupine (Chowdhury idr., 2013): (1) značilke v časovni domeni, (2) značilke v frekvenčni domeni in (3) značilke v časovno-frekvenčni domeni. Tipične značilke v časovni domeni so: povprečna absolutna vrednost, modificirana povprečna absolutna vrednost, povprečna absolutna vrednost naklona, enostaven kvadrat integrala, varianca, koren povprečja kvadratov, dolžina signala in amplituda Willison. Tipične značilke v frekvenčni domeni so (Phinyomark idr., 2009): povprečna in mediana frekvenca, modificirana povprečna in mediana frekvenca in avto regresivni koeficienti. Značilke časovno-frekvenčne domene se izračunajo s pomočjo metod, ki EMG signal pretvorijo v časovno-frekvenčno domeno (Chowdhury idr., 2013; Rafiee, Rafiee, Yavari, & Schoen, 2011). Takšne metode so: kratko-časovna Fourierjeva transformacija, Wigner-Ville distribucija in DVT.

Za klasifikacijo so bili v literaturi poročani različni pristopi s področja strojnega učenja. Najpogosteje se v literaturi pojavlja metoda podpornih vektorjev (*angl. support vector machine* (SVM)) (Cesqui, Tropea, Micera, & Krebs, 2013; Chowdhury idr., 2013; Oskoei, 2008), za katero je značilno, da dobro deluje na velikem številu vhodnih značilnik. Druge pogosto uporabljene metode so (Chowdhury idr., 2013; Hamedi, Salleh, Astaraki, & Noor, 2013; Angkoon Phinyomark idr., 2013, 2009): umetna nevronska mreža, logistična regresija in analiza linearne diskriminante.

Metoda SVM sodi med najbolj uspešne metode za klasifikacijo in regresijo in je primerna za učenje na velikih množicah z velikim številom manj pomembnih značilnk. Slaba stran metode SVM je zelo težavna interpretacija odločitev, podobno kot pri umetnih nevronske mrežah. V osnovi je klasifikacijska SVM namenjena razločevanju dveh razredov med seboj. Pri več razredih se postopek ponovi za vsak razred, ki ga želimo ločiti od ostalih razredov. Nov primer klasificiramo v razred z najvišjo vrednostjo odločitvene funkcije. Osnovno načelo metode SVM je v danem prostoru značilnk ločiti podana razreda, s postavitvijo hiperravnine, ki je enako in hkrati najbolj oddaljena od najbližjih primerov obeh razredov. Najbližji primeri hiperravnine so podporni vektorji, medtem ko je razdalja hiperravnine od podpornih vektorjev rob (*angl. margin*). Tako je optimalna hiperravnina tista, ki ima optimalni rob. Ker v izvornem prostoru linearna hiperravnina pogosto ne zadošča za zahtevano klasifikacijsko točnost, je potrebno ta prostor nelinearno transformirati. Transformacijo izbere uporabnik.

Nevronska mreža ali umetna nevrnska mreža (UNM) (*angl. artificial neural networks*) je zelo pogosto uporabljena metoda za strojno učenje, ki je bila zasnovana na podlagi do sedaj znanega modela delovanja človeških možganov. UNM je sestavljena iz umetnih nevronov, ki imajo več različno uteženih vhodov in en izhod. Umetni nevroni so med seboj povezani in organizirani v nivoje. Najpreprostejše UNM imajo le en nivo, medtem ko so kompleksnejše mreže sestavljene iz več nivojev. Nevroni, ki so matematično gledano pragovne funkcije, si po povezavah pošiljajo signale. Če je vsota vhodnih signalov dovolj velika, da preseže prag, pragovna funkcija sproži aktivacijo nevrona in na izhodu se pojavi signal. Model UNM je določen z velikostjo uteži povezav med nevroni in velikostjo praga v posameznem nevronu. Učenje modela UNM poteka z iterativnim spreminjanjem uteži povezav in praga. To poteka toliko časa, dokler ne dobimo optimalne rešitve problema predstavljenega z učno množico. Učenje UNM je lahko nadzorovano ali nenadzorovano. Pri nadzorovanem učenju se na podlagi vhodnih primerov, ki so sestavljeni iz množice neodvisnih spremenljivk in odvisne spremenljivke (razred), sestavi model, ki optimalno določi razred na podlagi neodvisnih spremenljivk. Večina algoritmov za učenje UNM uporablja neke vrste gradientno spuščanje (*angl. gradient descent*) s povratno zanko (*angl. backpropagation*) za adaptacijo uteži in praga.

Uspešnost klasifikacijske metode se lahko oceni z različnimi metodami. Najbolj pogosteje uporabljene so klasifikacijska točnost (KT), občutljivost in specifičnost. Rešitev vsakega primera klasifikacijskega problema je enolično določen razred iz množice možnih razredov. To lahko opredelimo kot razmerje med pravilnimi rešitvami primerov problema na danem področju in vsemi primeri, kar zapišemo kot

$$KT = \frac{N_p}{N} * 100 \%,$$

kjer je N_p število pravih rešitev in N število vseh primerov problema na danem področju. KT si lahko razložimo kot verjetnost, da bo naključno izbrani primer pravilno klasificiran. Občutljivost je statistična mera uspešnosti binarnega klasifikacijskega testa, ki meri odstotek pravilno prepoznanih pozitivnih primerov (npr. odstotek bolnih ljudi, ki so pravilno prepoznani kot bolni). Na drugi strani je specifičnost statistična mera uspešnosti binarnega klasifikacijskega testa, ki meri odstotek pravilno prepoznanih negativnih primerov (npr. odstotek zdravih ljudi, ki so pravilno prepoznani kot zdravi).

Predstavljene klasifikacijske metode spadajo v skupino metod nadzorovanega učenja. Takšne metode uporabijo učno množico za izgradnjo modela, ki ga nato uporabijo za klasifikacijo novih primerov. Kadar je množica primerov dovolj velika, jo lahko razdelimo na testno in učno množico. Učno množico uporabimo za učenje metode in nato naučen model preverimo na testni množici. Pomembno je, da učna in testna množica ne vsebujeta istih primerov, saj ni težko sestaviti modela, ki doseže 100 % KT na učni množici. To privede do pristranskosti ocenjevanja uspešnosti na testni množici. Če je na voljo malo vhodnih podatkov, se postopek učenja ne sme prikrajšati za primere testne množice. Tudi v tem primeru je potrebno oceniti uspešnost avtomatsko zgrajenega modela, vendar se tega ne sme narediti na učni množici. Metoda za ocenjevanje uspešnosti modela z malo primeri danega problema je metoda »izloči enega« (*angl. leave-one-out*). Ta metoda iz celotne množice izloči en primer in ga uporabi za testiranje uspešnosti modela, ki ga zgradi iz preostalih primerov. Postopek se ponovi za vsak primer posebej. Tako zgrajeni modeli so si med seboj zelo podobni, saj so bili zgrajeni na zelo podobni učni množici in imajo zato zelo podobno uspešnost. Uspešnost modela se določi kot povprečje uspešnosti vseh modelov. Metoda »izloči enega« je velikokrat časovno nesprejemljiva, zato se lahko posploši na izloči N/K primerov, čemur pravimo K -kratno prečno preverjanje (*angl. K-fold cross validation*). N je število vseh primerov in K je število modelov, ki jih je potrebno zgraditi. Najprej se množica razpoložljivih primerov razdeli na K približno enako močnih podmnožic. V vsakem koraku se za učenje uporabi $K - 1$ podmnožic. Zgrajeni model se uporabi za reševanje primerov na preostali podmnožici. Uspešnost končnega modela, ki se zgradi iz vseh razpoložljivih primerov, ocenimo kot povprečno uspešnost vseh K zgrajenih modelov. Pomanjkljivost K -kratnega prečnega preverjanja je različna zastopanost klasifikacijskih razredov v posameznih podmnožicah. Ta pomanjkljivost se odpravi z izpopolnjeno različico metode, ki se imenuje sorazmerno prečno preverjanje (*angl. stratified*

cross-validation). S tem pristopom se ohrani približno enako zastopanost razredov v vseh podmnožicah.

4 Cilji in hipoteze

4.1 Cilji:

- Razvoj metod za zanesljivo odstranjevanje motenj iz EMG signalov, kjer bo posebna pozornost namenjena EKG motnji.
- Razvoj metod za popolnoma avtomatsko (brez posredovanja uporabnika) iskanje začetka in konca mišične aktivacije.
- Določitev značilk za klasifikacijo mišic na take, ki imajo pričakovan/zdrav, in take, ki imajo nepričakovan/tvegan vzorec aktivacije.
- Povezava razvitih metod v celoto, ki bo omogočala avtomatsko obdelavo EMG signalov mišic človekovega trupa.

4.2 Hipoteze:

H1: Nove metode za odstranjevanje motenj iz EMG signalov bodo bolj zanesljive kot trenutno znane metode.

H2: Nove metode za iskanje začetka in konca mišične aktivacije bodo delovale popolnoma avtomatsko (brez posredovanja uporabnika).

H3: Izbrane značilke in klasifikacijska metoda bodo zanesljivo ločile mišice s pričakovanim/zdravim in nepričakovanim/tveganim vzorcem aktivacije.

H4: Vse razvite metode, povezane v celoto, bodo delovale popolnoma avtomatsko (brez posredovanja uporabnika).

5 Izvajanje meritev

Za primerno testiranje vseh faz raziskovalnega dela je bilo potrebno zagotoviti dovolj veliko količino ustrezno zbranih podatkov. Za izvajanje meritev je bila uporabljena oprema podjetja S2P, znanost v prakso, d.o.o., s katero smo izvedli meritve APP in PRO. Podjetje S2P d.o.o. ima tudi raziskovalno skupino »Laboratorij za motorično kontrolo in motorično obnašanje«, v kateri so strokovnjaki iz EMG področja, ki so poskrbeli za pravilno izvajanje meritev. Raziskovalna skupina ima bogate izkušnje z raziskovalnimi meritvami v biomehaniki in upravljanju gibanja, katere del so tudi raziskave z EMG področja. Med pripravo na same meritve smo se srečali z različnimi mehanskimi in elektronskimi izzivi, ki smo jih rešili skupaj s primerno usposobljenimi zunanjimi sodelavci podjetja.

Slika 5.1: Namensko izdelana merilna naprava za izvajanje meritev.



Meritve smo izvedli s pomočjo namensko izdelane merilne naprave (Slika 5.1). Naprava je bila sestavljena iz sistema za zajem EMG signalov, modula za generiranje motenj med mirno stoji (sprostilni elektromagnetni mehanizem za nenadno aplikacijo obremenitve na roke preiskovanca), sistema za merjenje začetka hotenega dviga rok in programske opreme za krmiljenje vseh sistemov ter zajema vseh potrebnih podatkov. Merilna naprava skupaj z vso

potrebno programsko opremo je bila izdelana v podjetju S2P d.o.o. s pomočjo zunanjih sodelavcev. Sistem za zajem EMG signalov je bil lastne izdelave in je bil validiran z dvema drugima komercialnima EMG sistemoma.

5.1 Preiskovanci


V raziskavo je bilo vključenih 125 preiskovancev (112 moškega in 13 ženskega spola) povprečno starih $41,1 \pm 9,0$ let (od 23 do 62 let), povprečno visokih $180,6 \pm 6,6$ cm in povprečno težkih $89,7 \pm 14,4$ kg. Simptome BSH je imelo 28 preiskovancev, medtem ko je bilo ostalih 97 preiskovancev zdravih. Preiskovancem smo pred začetkom meritev podrobno predstavili namen in potek raziskave v skladu s Helsinško deklaracijo in Oviedsko konvencijo. Vsi preiskovanci so podpisali izjavo o zavestni in svobodni privolitvi. Metodologijo te raziskave je odobrila Republiška strokovna komisija za medicinska in etična vprašanja (št. odobritve: 107/01/12). Raziskava je bila del širšega nacionalnega raziskovalnega projekta »ARRS šifra: L5-4293: Vrednotenje živčno-mišičnih stabilizacijskih funkcij trupa in razvoj programov preventivne vadbe proti bolečini v spodnjem delu hrbta«.

5.2 Priprava merjencev in zajem signalov

Preiskovanci so pred meritvami opravili standardizirano ogrevanje. Sledila je priprava kože (čiščenje z alkoholom, britje in odstranjevanje odmrlega sloja kože) in namestitev 9-ih parov EMG elektrod Blue Sensor N (Ambu A/S, Denmark) za enkratno uporabo. Pari elektrod na vsaki mišici so bili razmaknjeni 2 cm (razdalja med središčema obeh elektrod) (Merletti & Parker, 2004). EMG mišic smo odjemali obojestransko (levo in desno) na m. multifidus (MF), m. erektor spinae (ES) in m. obliquus externus (OE), ter na levi polovici telesa na m. rectus abdominis (RA), m. obliquus internus (OI) in sprednjem delu m. deltoideus (DA) (Slika 5.2). Elektrodi na mišici MF sta bili nameščeni v višini trnastega odrastka petega ledvenega vretenca. Elektrodi sta bili postavljeni na navidezno črto med zadnjim zgornjim trnom črevnice (lat.: spina iliaca posterior superior) ter odmaknjeni lateralno 2 do 3 cm od sredine hrbta (Hibbs idr., 2011; Masani idr., 2009; Stokes, Fox, & Henry, 2006). Elektrodi na mišici ES (longissimus thoracis pars lumborum) sta bili postavljeni v višini prvega ledvenega trnastega odrastka hrbtenice in vertikalno orientirani. OE smo odjemali nad sprednjim zgornjim trnom črevnice (lat.: anterior superior iliac spine) v višini popka in orientirani pod kotom 45° lateralno

glede na vertikalno os (Masani idr., 2009; Radebold idr., 2000). Par elektrod na mišici RA je bil nameščen 3 cm desno od popka in orientiran vertikalno. Elektrodi na mišici OI sta bili nameščeni nad ingvinalni ligament 2 cm medialno in 2 cm kavalno od sprednjega zgornjega trna črevnice (Hibbs idr., 2011; Radebold idr., 2000) in orientiran pod kotom 45° v medialni smeri glede na vertikalno linijo. DA smo odjemali s parom elektrod, postavljenih na imaginarno črto med sprednjim delom akromiona in palcem, 2 cm anteriorno in 2 cm lateralno od sprednjega roba akromiona.

Slika 5.2: Postavitev EMG elektrod na levi polovici telesa.



EMG signali so bili ob zajemu 750-kratno ojačani in vzorčeni s 3000 Hz. Za zajem in pretvorbo analognih signalov v digitalne smo uporabili več-funkcijsko napravo za zajem signalov NI USB-6210 (National Instruments, Texas, USA). Za zajem signalov smo uporabljali po meri narejeno aplikacijo, izdelano v razvojnem okolju Labview (National Instruments, Texas, USA). Aplikacija je omogočala sočasen zajem vseh signalov in njihov prikaz na zaslону v realnem času, kar je omogočalo sprotno preverjanje kakovosti signalov. Hkrati je aplikacija omogočala generiranje naključnih prožilnih signalov za sprostilni elektromagnetni mehanizem pri nenadni obremenitvi rok pri nalogi PRO in zvočni znak za hiter dvig rok pri nalogi APP.

5.3 Protokoli meritev

Preiskovanec je bil ob prihodu na meritev najprej seznanjen z namenom raziskave in celotnim potekom meritev. Potem je opravil standardizirano ogrevanje, ki je bilo sestavljeno iz 5 min stopanja na stopnico (menjava vodilne noge vsakih 30 s), soročnega kroženja z rokami (30 s v vsako smer), kroženja z boki (30 s v vsako smer) in 10-ih počepov. Temu je sledila namestitev EMG elektrod.

Protokol meritev je bil sestavljen iz dveh delov. Preiskovanci so najprej izvedli nalogo hitrega dvigovanja rok do višine ramen z namenom vrednotenja APP. Nato so sledile meritve stabilizacije po nenadni mehanski motnji z namenom vrednotenja PRO. Zaradi večje verjetnosti utrujanja pri izvajanju naloge, je bila naloga hitrega dvigovanja rok do višine ramen narejena prva.

5.4 Meritve anticipacijskih posturalnih prilagoditev

Preiskovanec je pri meritvi APP (Slika 5.3) stal sproščeno s stopali poravnanimi vzporedno in v širini bokov. V rokah je držal palico z maso 1 kg. Roke je imel sproščene in iztegnjene, tako da je bila palica prislunjena na sprednjo stran bokov. Na palici je bil nameščen pospeškometer, ki se je uporabljal za zaznavanje začetka hotenega dviga rok. Na zvočni signal je preiskovanec dvignil roke, kar se da hitro, do višine ramen, jih zadržal 1 s in počasi spustil v izhodiščni položaj. Dvig rok je moral izvesti v 1 s po zvočnem signalu. Zvočni signal je bil sprožen naključno na vsakih 8 do 12 s. Preiskovanec je naredil 20 ponovitev naloge.

Slika 5.3: Izvajanje APP naloge.

5.5 Meritve posturalnih reakcij na obremenitev

Preiskovanec je pri meritvi PRO (Slika 5.4) stal sproščeno s stopali poravnanimi vzporedno in v širini bokov ter obrnjen proti merilnemu stolpu. Roke je imel ob telesu s pokrčenimi komolci za 90°. Dlani je imel obrnjene navzgor in tik pod ročko z utežmi (breme), ki je bila pripeta na sprostilni elektromagnetni mehanizem. Masa bremena je bila določena relativno glede na maso preiskovanca, tako da je znašala 8 % ($\pm 0,5$ kg) telesne mase preiskovanca. Breme se je sprostito naključno na vsakih 8 do 12 s. Naloga preiskovanca je bila, da ob padcu bremena na dlani le-tega čim hitreje zadrži/stabilizira in se umiri. Preiskovanec je naredil 20 ponovitev naloge.

Slika 5.4: Izvajanje PRO naloge.



6 Obdelava podatkov

Predhodno smo predstavili problem, katerega rešujemo, že uporabljene pristope za EMG, obdelavo iz literature in potek izvedbe meritev, s katerimi smo pridobili potrebne podatke za naše delo. V tem razdelku si bomo podrobno pogledali postopke obdelave EMG signalov s človeškega trupa, ki smo jih razvili in uporabili pri tej nalogi. Dodatno smo opisali tudi nekatere postopke, ki smo jih razvili, vendar na koncu niso privedli do zadovoljivih rezultatov. Obdelava podatkov je bila v veliki večini narejena v razvojnem okolju Labview (National Instruments, Texas, USA), ki je zelo dobro opremljeno z bogatimi knjižnicami za obdelavo signalov. Nekateri deli obdelave podatkov so bili narejeni v okolju Matlab (MathWorks, Massachusetts, USA) in Microsoft Excel-u (Microsoft, Washington, USA). Obdelava podatkov je potekala po sledečih stopnjah: predobdelava EMG signalov, odstranjevanje EKG motnje iz EMG signala, iskanje začetka in konca mišične aktivacije ter izračun značilk in klasifikacija. Predhodno je bilo potrebno zajete meritve ustrezno pripraviti za obdelavo po naštetih stopnjah. To predstopnjo obdelave imenujemo čiščenje podatkov. V tem vrstnem redu sledi tudi podroben opis vsake izmed naštetih stopenj obdelave EMG signalov.

6.1 Čiščenje podatkov

Pri meritvah se občasno zgodi, da pride do napake zaradi različnih vzrokov (npr. napačna izvedba naloge, premaknitev EMG elektrode ipd.). Zato je potrebno takšne meritve ali dele meritev odstraniti. Večino napak smo opazili že med samim izvajanjem meritev, kjer se je takšna meritev takoj izbrisala in ponovila. Včasih se je zgodilo, da smo napako med izvajanjem meritve spregledali in jo opazili šele, ko je preiskovanec že zaključil z meritvijo in odšel. V tem primeru smo to zapisali in se je takšna meritev ali del meritve pred nadaljnjo obdelavo odstranil. Če se je napaka pojavila, ko smo naredili že večino meritve in je bilo zato celotno ponavljanje meritve nesmiselno, smo meritev shranili in dodatno izvedli le manjkajoči del meritve. Takšne meritve je bilo potrebno ustrezno obravnavati pred nadaljnjo obdelavo. Najprej se je del meritve, kjer je prišlo do napake, odstranil in se je nato preostalemu delu meritve dodala dodatno narejena meritev. Število meritev, pri katerih je bila potrebna takšna obravnava, je bilo majhno (približno 3 %).


Za namen čiščenja podatkov smo razvili program, ki na podlagi zapiskov ustrezno očisti podatke meritev. Program omogoča odstranjevanje celotne meritve ali posamezne mišice iz meritve kakor tudi določenega dela celotne meritve ali določenega dela posamezne mišice iz meritve. Dodatno omogoča tudi združevanje dveh meritev. Z opisano funkcionalnostjo se pokrijeta oba primera napak med meritvijo, ki sta opisana v predhodnem odstavku. Čiščenje podatkov poteka avtomatsko na podlagi ustrezno urejenih zapiskov meritev, s čimer se izognemo zamudnemu in monotonemu ročnemu delu.

6.2 Predobdelava EMG signalov

V stopnji predobdelave EMG signalov se želimo znebiti motenj (šumov), ki so lahko različnega izvora. Podrobnejši opis motenj je bil podan v razdelku 3.1.1. V razdelku 3.1.1 so bile predstavljene metode, ki so se pogosto uporabljale za odstranjevanje motenj (pasovno filtriranje, odstranjevanje motenj z DVT in odstranjevanje motenj z EMD). Na podlagi izvedenih testov smo se odločili, da za to stopnjo obdelave EMG signala ne razvijamo novih algoritmov, ampak uporabimo obstoječe metode. Razlogi za takšno odločitev so podani v nadaljevanju.

Nizkofrekvenčne motnje, katerih izvor je večinoma v mehanskih premikih elektrod ali kabla, se odstrani z visoko prepustnim filtrom. Takšen filter odstrani spekter nizkih frekvenc in ohrani frekvenčni spekter nad določeno frekvenčno mejo. Zastopanost frekvenčnega spektra EMG signala je med 0 in 500 Hz (De Luca, 1997), vendar je zastopanost frekvenc, manjših od 3 Hz zelo majhna. Če odstranimo frekvenčni spekter, manjši od 3 Hz, bomo izgubili zelo majhen del EMG signala (do 0,5 %) in hkrati odstranili motnje, ki so posledica mehanskih premikov elektrod ali kabla (Slika 6.1).


Slika 6.1: Uporaba visoko pasovnega filtra za odstranjevanje nizko frekvenčnih motenj.



(A) izvoren EMG signal. (B) EMG signal obdelan z Butterworth visoko prepustnim filtrom s prepustnim pasom nad 3 Hz in stopnjo 2.

Ker visoko prepustni filter ni primeren za odstranjevanje interference naključnega šuma (Phinyomark idr., 2009b), uporabimo za ta namen odstranjevanje šuma z DVT. Postopek odstranjevanja šuma z DTV je bil podrobno opisan v razdelku 3.1.1. Odstranjevanje šuma z DVT je primerno za avtomatsko obdelavo EMG signalov, v kolikor vemo, kakšno izhodiščno valčno funkcijo in katero število nivojev dekompozicije je najprimernejše uporabiti. Takšna izbira omenjenih parametrov vnaprej je problematična, saj lahko pomembno vpliva na rezultat. Primer slabe izbire izhodiščne valčne funkcije je prikazan na Sliki 6.2.

Slika 6.2: Primer odstranjevanja šuma z DVT.



(A) primer EMG signala (rdeč črta), ki je obdelan z DVT metodo za odstranjevanje šuma (črna črta). (B) močnostna spektra obeh signalov iz (A).

Za ta primer je bila uporabljena DVT z Daubechies (db2) izvorno valčno funkcijo in štirimi nivoji dekompozicije, ki je bila v literaturi predlagana kot najprimernejša za odstranjevanje belega Gaussovega šuma (Phinyomark idr., 2009b). Iz močnostnega spektra je razvidno, da DVT odstrani pomemben del EMG spektra v območju med 35 in 170 Hz, česar si seveda ne želimo. To lahko pomeni napačno interpretacijo nadaljnje analize EMG signala.

Za postopek odstranjevanja šuma z empirično razgradnjo so bili pokazani boljši rezultati v primerjavi z odstranjevanjem z valčno analizo (Andrade idr., 2006). Slabost odstranjevanja šuma z EMD je ročno določanje okna, na katerem je prisoten samo šum brez EMG signala. Ta slabost pomeni, da EMD ni primerna za avtomatsko obdelavo EMG signalov in je zato nismo uporabili v tej nalogi. V kolikor bi se okno šuma določilo avtomatsko s primernim algoritmom, bi EMD metoda predstavljala boljšo alternativo DVT. V tej nalogi se nismo lotili reševanja tega problema, ker smo skladno z upoštevanjem naslednjih stopenj obdelave EMG signala ocenili, da to ne bi doprineslo k znatnemu izboljšanju avtomatske obdelave EMG signalov.

Za avtomatsko obdelavo EMG signalov smo v tej nalogi izbrali Butterworth pasovno prepustni filter s prepustnim pasom med 3 in 500 Hz, stopnjo 2 in ničelnim faznim zamikom (*angl. zero lag*). Za odstranjevanje frekvenčnega spektra pod 3 Hz smo se odločili zaradi odstranjevanja motenj, ki so posledica mehanskih premikov elektrod ali kabla, in hkrati zanemarljive izgube EMG signala. Ker nad 500 Hz ni pričakovati EMG signala (De Luca, 1997), smo odstranili tudi ta del frekvenčnega spektra. Za ničeni fazni zamik smo se odločili, ker bomo nekatere značilke časovno primerjali s signali, ki se ne bodo filtrirali z istim filtrom in bi zato prišlo do napake v rezultatih. Butterworth filter s stopnjo 2 smo izbrali na podlagi analize močnostnih spektrov, pridobljenih z uporabo različnih družin filtrov (Butterworth, Chebyshev in Bessel) in različnih stopenj (1 do 6). Odstranjevanje šuma z DVT smo vključili v aplikacijo za avtomatsko obdelavo EMG signalov, vendar je pri samem postopku avtomatske obdelave nismo uporabili. Razlog za to je v odstranjevanju pomembnega dela EMG signala, kot je to razvidno iz Slike 6.2. V primeru, da se uporabnik odloči uporabiti DVT za avtomatsko odstranjevanje šuma, mora predhodno izbrati ustrezno izvorno valčno funkcijo in število nivojev dekompozicije.

6.3 Odstranjevanje EKG motnje iz EMG signala

EKG motnja v EMG signalu je posledica delovanja srca in je zelo pogosta pri mišicah blizu srca. Vsebnost EKG motnje v EMG signalu je problematična zaradi dveh razlogov: (1) je vsebovana v aktivnem delu EMG signala, kar vpliva na izračun značilk; ali (2) je vsebovana v neaktivnem delu EMG signala, kar predstavlja problem pri zaznavanju začetka mišične aktivacije in tudi pri izračunu značilk neaktivnega dela EMG signala. Glavno težavo pri odstranjevanju EKG motnje predstavlja prekrivanje EMG in EKG frekvenčnega spektra, kar je podrobno opisano v razdelku 3.1.2. V tem razdelku so opisane tudi metode, ki so bile predlagane v literaturi za odstranjevanje EKG motnje skupaj z njihovimi prednostmi in slabostmi. Na podlagi pregleda literature smo ugotovili, da problem odstranjevanja EKG motnje ni bil zadovoljivo rešen in/ali ni primeren za avtomatsko obdelavo EMG signalov mišic trupa. Osnovne zahteve, katerim je morala zadostiti primerna metoda, so bile: uporaba brez posredovanja uporabnika, uporaba brez dodatno zajetega EKG signala, uporaba brez upoštevanja drugih EMG kanalov, uporaba brez znanja, pridobljenega iz učne množice ter ocena zanesljivosti zaznave EKG motnje. S temi kriteriji smo zagotovili primernost metode za avtomatsko obdelavo EMG signalov.


V nadaljevanju bomo najprej na kratko povzeli pristope s, katerimi smo poskušali rešiti zadani problem, vendar nam z njimi tega ni uspelo rešiti zadovoljivo. Potem si bomo podrobno

pogledali novo metodo za odstranjevanje EKG motnje, ki smo jo razvili v okviru te naloge. Na koncu sledi še ovrednotenje uspešnosti nove metode in razprava.

6.3.1 Preizkušani pristopi za odstranjevanje EKG motnje

Prvi pristop za odstranjevanje EKG motnje iz EMG signala, s katerim smo se lotili reševanja problema, je bila kombinacija EMD in ICA metode, ki smo jo podrobneje opisali v razdelku 3.1.2. Taelman in sodelavci (2011) so v svoji študiji pokazali, da je ta pristop uspešen, v kolikor predhodno vemo, iz koliko različnih (neodvisnih) virov je sestavljen obravnavani EMG signal. Naši preliminarni testi so pokazali, da metoda ni primerna za odstranjevanje EKG motnje iz EMG signala, saj iz komponent, pridobljenih z ICA metodo, nismo mogli določiti tistih, ki vsebujejo samo EKG motnjo. Zato smo poskusili problem rešiti z odpravo problema mešanja komponent, pridobljenih z EMD, ki ga avtorji v svoji študiji niso obravnavali. Ta se odrazi tako, da se močnostni spektri komponent, pridobljenih z EMD, prekrivajo. Wu in Huang (2009) sta predlagala metodo EEMD, ki sicer omili problem, vendar ga ne reši popolnoma. Nadalje so Torres in sodelavci (2011) predlagali metodo, ki še boljše ločuje komponente, kar pomeni manjše prekrivanje močnostnih spektrov posameznih komponent ter tako zagotovi »popolnost« dekompozicije. Posledica tega je, da se osnovni signal razstavi na manjše število komponent (IMF-jev). Metodo so poimenovali popolna empirična razgradnja z adaptivnim šumom (*angl. complete ensemble empirical mode decomposition with adaptive noise* (CEEMD)). Predpostavili smo, da bomo s CEEMD metodo dobili boljše IMF-je, na podlagi katerih bo ICA lahko izluščila EKG signal od ostalih signalov. Število neodvisnih virov za ICA metodo smo nastavili na pet (Mijović, De Vos, Gligorijević, Taelman, & Van Huffel, 2010). Testiranje opisane metode je pokazalo, da tudi s to metodo ne moremo zanesljivo ločiti EKG signala od ostalega dela EMG signala, kar si bomo pogledali na naslednjem primeru (Slika 6.3). EMG signal (Slika 6.3 A) smo razstavili na 11 IMF komponent s CEEMD metodo (Slika 6.3 B). Nato smo z ICA metodo iz 11 IMF-jev naredili pet neodvisnih komponent (Slika 6.3 C). Očitno je, da nobena od dobljenih komponent ne predstavlja EKG signala oziroma je ta vsebovan v več komponentah. S spreminjanjem števila virov (med 2 in 9) nismo dobili boljših rezultatov. Na podlagi navedenega smo se odločili, da nadaljnji razvoj te metode opustimo.


Slika 6.3: Postopek odstranjevanja EKG motnje iz EMG signala s kombinacijo CEEMD in ICA.



(A) EMG signal. (B) 11 komponent pridobljenih s CEEMD iz (A). (C) 5 neodvisnih komponent pridobljenih z ICA metodo iz (B).

Drug pristop, s katerim smo poskušali rešiti problem odstranjevanja EKG motnje iz EMG signala, je temeljil na kombinaciji empirične valčne transformacije (EVT) (*angl. empirical wavelet transform*) in ICA metode. EVT metoda je podrobno opisana v (Gilles, 2013). Na kratko, EVT razstavi vhodni signal na komponente podobno kot EMD metoda. Število komponent se lahko določi ročno ali se izračuna z algoritmom. Gilles (2013) je pokazal, da EVT razstavi signal na bolj skladne komponente v primerjavi z EMD metodo. EMD metoda v splošnem naredi preveč komponent, ki jih je včasih zelo težko interpretirati. Na podlagi naštetih prednosti EVT metode v primerjavi z EMD metodo smo se odločili, da jo uporabimo za razstavljanje EMG signala na komponente. Tako dobljene komponente nato uporabi ICA metoda za določanje neodvisnih izvorov in s tem ločevanje EKG signala od ostalih izvornih signalov. Podobno kot pri prejšnjem pristopu CEEMD-ICA smo tudi tukaj nastavili število neodvisnih izvorov za ICA metodo na pet. Testiranje opisane metode je pokazalo, da tudi s tem pristopom ne moremo zanesljivo izločiti EKG signala od ostalega dela EMG signala, kar je razvidno iz naslednjega primera (Slika 6.4). EMG signal (Slika 6.3 A) je bil z EVT metodo razstavljen na pet komponent (Slika 6.4 A). Število komponent se je določilo z algoritmom. Nato je ICA metoda iz teh petih komponent naredila pet neodvisnih komponent (Slika 6.4 B). Podobno kot pri CEEMD-ICA metodi tudi tukaj nobena od dobljenih komponent ne predstavlja EKG signala. Tudi spreminjanje števila izvorov (med 2 in 9) ni prineslo izboljšanja rezultatov. Še najbolj je EKG signalu podobna skrajno spodnja komponenta (Slika 6.4 A) EVT dekompozicije, vendar poleg EKG signala vsebuje tudi zelo veliko EMG signala. Iz navedenega smo zaključili, da ta pristop ni primeren za odstranjevanje EKG motenj pri avtomatski obdelavi EMG signalov.

Slika 6.4: Postopek odstranjevanja EKG motnje iz EMG signala s kombinacijo EVT in ICA



(A) 5 komponent pridobljenih z EVT iz EMG signala (Slika 6.3 A). (B) 5 neodvisnih komponent pridobljenih z ICA metodo iz (A).

6.3.2 Nova metoda za odstranjevanje EKG motnje iz EMG signala

Predlagana nova metoda za odstranjevanje EKG motnje iz EMG signala temelji na metodi dinamičnega časovnega sledenja (*angl. dynamic time warping (DTW)*). DTW se uporabi za iskanje vzorcev, ki so podobni EKG artefaktu. Vzorci se iščejo na predhodno ustrezno obdelanem EMG signalu. Iz množice najdenih kandidatov EKG artefaktov se nato izlušči tiste, ki

na podlagi EKG lastnosti (širina artefakta in cikel) najbolj ustrezajo EKG artefaktom. Na koncu se od izvirnega EMG signala odšteje predhodno ustrezno obdelan EMG signal samo na intervalih, kjer so prisotni EKG artefakti. Na ta način se preostali del EMG signala popolnoma nič ne spremeni.

6.3.2.1 Dinamično časovno sledenje

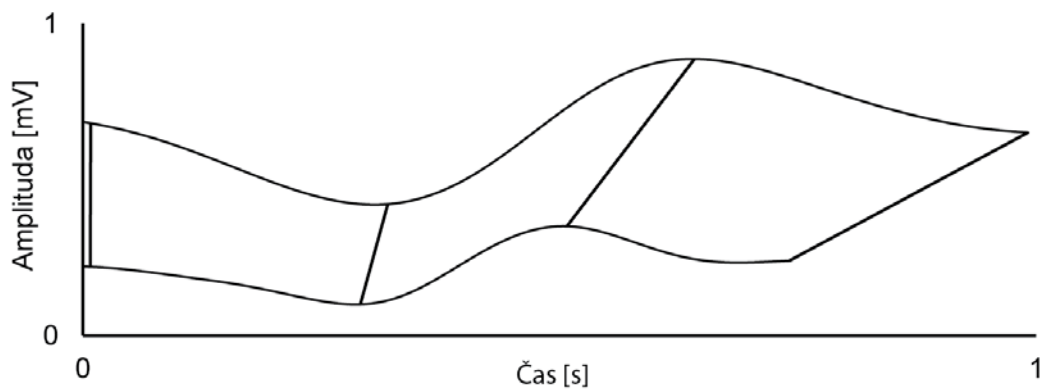
DTW (Müller, 2007) je uveljavljena metoda za iskanje optimalne poravnave med dvema podanima zaporedjema, ki sta časovno odvisni. DTW izračuna optimalno ujemanje dveh zaporedij z določenimi omejitvami. Metoda nelinearno »sledi« podani zaporedji in na ta način oceni njuno podobnost ne glede na nelinearne variacije v času. Prvotno se je DTW uporabljala za primerjavo različnih govornih vzorcev pri avtomatski razpoznavi govora (Rabiner & Juang, 1993). DTW je bila pogosto uporabljena še za primerjavo podobnosti med dvema zaporedjema, pri klasifikaciji zaporedij in pri iskanju vzorcev v zaporedjih.

DTW v osnovi primerja dve časovno odvisni zaporedji $X = (x_1, x_2, \dots, x_N)$ dolžine $N \in \mathbb{N}$ in $Y = (y_1, y_2, \dots, y_M)$ dolžine $M \in \mathbb{N}$. Vrsti X in Y sta lahko poljubni vrsti značilnk, ki sta vzorčeni v ekvidistančnih točkah v času (npr. časovna vrsta, diskretni signal). F opredelimo kot *prostor značilnk*, tako, da je $x_n, y_m \in F$ za $n \in [1: N]$ in $m \in [1: M]$. Za primerjavo dveh različnih značilnk $x, y \in F$ potrebujemo *mero lokalno cene* imenovano tudi *mera lokalne razdalje*, ki je opredeljena kot

$$c: F \times F \rightarrow \mathbb{R}_{\geq 0}.$$

Če sta x in y podobna, je $c(x, y)$ nizka, in obratno, če sta x in y različna, je $c(x, y)$ visoka. Če izračunamo lokalno mero razdalje za vse možne pare zaporedij X in Y , dobimo matriko lokalnih cen $C \in \mathbb{R}^{N \times M}$ opredeljeno z $C(n, m) = c(x_n, y_m)$. Cilj je najti takšno poravnavo (Slika 6.5) med X in Y , da je skupna cena najmanjša.

Slika 6.5: Časovna poravnava dveh časovno odvisnih zaporedij.




Štiri točke poravnave so označene s črtami.

Takšna optimalna poravnava teče po »dolini« nizkih cen matrice cen. Optimalno poravnavo zapišemo kot (N, M) -pot sledenja in je opredeljena kot zaporedje $p = (p_1, p_2, \dots, p_L)$ z $p_l = (n_l, m_l) \in [1:N] \times [1:M]$ za $l \in [1:L]$, ki zadosti naslednjim trem pogojem:

- (a) Robni pogoj: $p_1 = (1, 1)$ in $p_L = (N, M)$.
- (b) Pogoj monotonosti: $n_1 \leq n_2 \leq \dots \leq n_L$ in $m_1 \leq m_2 \leq \dots \leq m_L$.
- (c) Pogoj velikosti koraka: $p_{l+1} - p_l \in \{(1, 0), (0, 1), (1, 1)\}$ za $l \in [1:L-1]$ (Slika 6.6).

Slika 6.6: Grafična predstavitev pogoja velikosti koraka.



Pogoj monotonosti (b) izhaja iz samega pogoja velikosti koraka (c) in je posebej zapisan samo zaradi jasnosti opredelitve. (N, M) -pot sledenja $p = (p_1, p_2, \dots, p_L)$ opredeljuje poravnavo med dvema zaporedjema $X = (x_1, x_2, \dots, x_N)$ in $Y = (y_1, y_2, \dots, y_M)$ z dodelitvijo elementa x_{n_l} iz X elementu y_{m_l} iz Y . Robni pogoj vsili poravnavo prvih elementov iz X in Y kot tudi zadnjih elementov iz X in Y enega z drugim. To pomeni, da algoritem poravnave zajame vse elemente iz X in Y enega z drugim. Pogoj monotonosti zagotavlja zahtevo po sosednosti poravnave, kar pomeni, da, če je element iz X pred drugim elementom, mora to veljati tudi za ustrezen element iz Y in obratno.

Pogoj velikosti koraka izraža kontinuiteto: noben element iz X in Y ne sme biti izpuščen in ni nobene ponovitve v poravnavi, kar pomeni, da so vsi pari v poti sledenja različni med sabo.

Skupna cena $c_p(X, Y)$ poti sledenja p med X in Y glede na mero lokalne cene c je opredeljena kot

$$c_p(X, Y) = \sum_{l=1}^L c(x_{n_l}, y_{m_l}).$$

Optimalna pot sledenja med X in Y je pot sledenja p^* , ki ima najmanjšo skupno ceno med vsemi možnimi potmi sledenja. DTW razdalja $DTW(X, Y)$ med X in Y je opredeljena kot skupna cena p^* :

$$DTW(X, Y) = c_{p^*}(X, Y) = \min\{c_p(X, Y) \mid p \text{ je } (N, M) - \text{pot sledenja}\}.$$

DTW razdalja ima naslednje lastnosti:

- (a) DTW razdalja je dobro opredeljena (tudi, če obstaja več poti z najmanjšo skupno ceno),
- (b) DTW razdalja je simetrična, ko je tudi mera lokalne cene c simetrična,
- (c) DTW razdalja v splošnem ni pozitivno določna, četudi to drži za c ,
- (d) DTW razdalja v splošnem ne izpolni trikotniške neenakosti.

Za iskanje optimalne poti p^* lahko preverimo vse možne poti sledenja med X in Y . Takšen pristop bi vodil k eksponentni časovni kompleksnosti. Boljši algoritem za iskanje optimalne poti p^* temelji na načelu dinamičnega programiranja in ima časovno kompleksnost $O(NM)$.

$$D(n, m) = DTW(X(1:n), Y(1:m)),$$

kjer je $D(n, m)$ matrika D velikosti $N \times M$ imenovana matrika akumuliranih cen (Slika 6.7), $X(1:n) = (x_1, \dots, x_n)$ za $n \in [1:N]$ in $Y(1:m) = (y_1, \dots, y_m)$ za $m \in [1:M]$. Očitno je $D(N, M) = DTW(X, Y)$. Naslednji izrek prikazuje, kako lahko učinkovito izračunamo D .

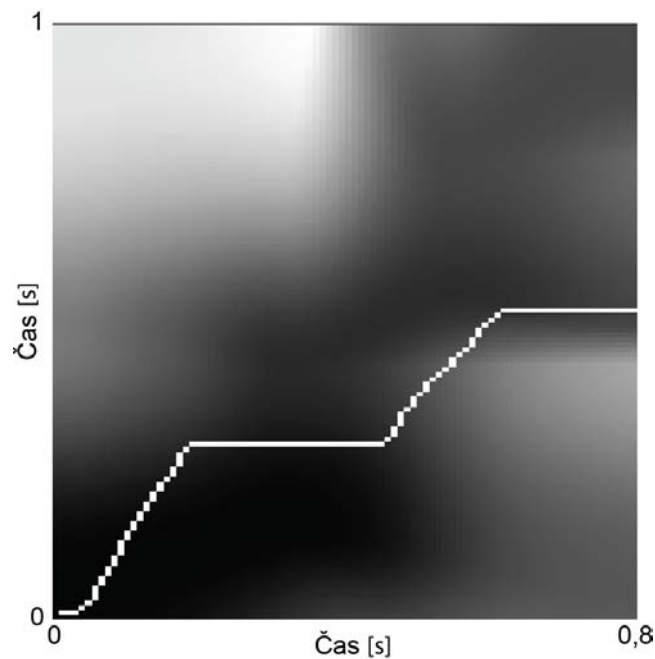
Matrika akumuliranih cen D izpolnjuje naslednje enakosti:

- $D(n, 1) = \sum_{k=1}^n c(x_k, y_1)$ za $n \in [1:N]$,
- $D(1, m) = \sum_{k=1}^m c(x_1, y_k)$ za $m \in [1:M]$,
- $D(n, m) = \min\{D(n-1, m-1), D(n-1, m), D(n, m-1)\} + c(x_n, y_m)$ za $1 < n \leq N$ in $1 < m \leq M$.

Torej, $DTW(X, Y) = D(N, M)$ lahko izračunamo z $O(NM)$ operacijami. Dokaz je podan v (Müller, 2007).

Podana opredelitev določa rekurzivni izračun matrike D . Inicializacijo lahko poenostavimo z razširitvijo matrike D z dodatno vrstico in stolpcem, tako da nastavimo $D(n, 0) = \infty$ za $n \in [1: N]$, $D(0, m) = \infty$ za $m \in [1: M]$ in $D(0, 0) = 0$. Tedaj rekurzija velja za $n \in [1: N]$ in $m \in [1: M]$. Da izračunamo optimalno pot sledenja p^* (Slika 6.7 – p^* je označena z belo črto), potrebujemo celotno matriko ($N \times M$).

Slika 6.7: Matrika akumuliranih cen.



Matrika akumuliranih cen je izračunana za signala, prikazana na Sliki 6.5. Z belo črto je označena optimalna pot sledenja p^* .

Algoritem za izračun optimalne poti sledenja p^* :

- (1) Vhod je matrika akumuliranih cen D .
- (2) Izhod je optimalna pot sledenja p^* .
- (3) Začnemo s $p_L = (N, M)$.
- (4) Predpostavimo, da je $p_l = (n, m)$ izračunan. Če $(n, m) = (1, 1)$, potem je $l = 1$ in zaključimo postopek. Če ni, potem nadaljujemo z naslednjim korakom.
- (5)
$$p_{l-1} = \begin{cases} (1, m - 1), & \text{če } n = 1 \\ (n - 1, m), & \text{če } m = 1 \\ \operatorname{argmin}\{D(n - 1, m - 1), D(n - 1, m), D(n, m - 1)\}, & \text{drugače} \end{cases}$$

Če »argmin« ni unikatno, vzamemo leksikografsko najmanjši par.

Za pohitritev izračuna DTW in boljšega nadzora možnih smeri poti sledenja so bile predlagane različne izvedenke. Tukaj bomo opisali samo izvedenko z lokalnimi utežmi, medtem ko so ostale izvedenke opisane v (Rabiner & Juang, 1993).

Z lokalnimi utežmi lahko dosežemo favoriziranje vertikalne, horizontalne ali diagonalne smeri. Lokalne uteži predstavimo z dodatnim vektorjem uteži $(w_v, w_h, w_d) \in \mathbb{R}^3$. Posledično lahko zapišemo rekurzijo

$$D(n, m) = \min \begin{cases} D(n-1, m-1) + w_d * c(x_n, y_m) \\ D(n-1, m) + w_h * c(x_n, y_m) \\ D(n, m-1) + w_v * c(x_n, y_m) \end{cases}$$

za $n \in [2:N]$ in $m \in [2:M]$. Dalje, $D(n, 1) = \sum_{k=1}^n w_h * c(x_k, y_1)$ za $n > 1$, $D(1, m) = \sum_{k=1}^m w_v * c(x_1, y_k)$ za $m > 1$, in $D(1, 1) = c(x_1, y_1)$. Enakomerno utežen primer $(w_v, w_h, w_d) = (1, 1, 1)$ daje prednost poravnavi v diagonalni smeri, zato ker en korak v diagonalni smeri (cena ene celice) ustreza kombinaciji enega horizontalnega in enega vertikalnega koraka (cena dveh celic). Kot protiutež temu lahko izberemo $(w_v, w_h, w_d) = (2, 1, 1)$.

6.3.2.2 Iskanje podzaporedij z dinamičnim časovnim sledenjem

V veliko primerih želimo poiskati podzaporedja (vzorci) v časovnih vrstah (npr. v digitalnih signalih). Pri tem si lahko pomagamo z DTW pristopom, ki ga moramo ustrezno prilagoditi (Müller, 2007). Namesto da primerjamo dve zaporedji globalno, primerjamo krajše zaporedje z vsemi podzaporedji daljšega zaporedja. V tem primeru iščemo optimalno ujemanje krajšega zaporedja s podzaporedjem daljšega zaporedja. Sledi opis DTW algoritma za iskanje podzaporedij.

Naj bosta $X = (x_1, x_2, \dots, x_N)$ dolžine $N \in \mathbb{N}$ in $Y = (y_1, y_2, \dots, y_M)$ dolžine $M \in \mathbb{N}$ zaporedji, kjer je M veliko večji kot N . Cilj je poiskati takšno podzaporedje $Y(a^*, b^*) = (x_{a^*}, x_{a^*+1}, \dots, x_{b^*})$ z $1 \leq a^* \leq b^* \leq M$, da minimizira DTW razdaljo do X za vsa možna podzaporedja na Y , kar lahko zapišemo kot

$$(a^*, b^*) = \underset{(a,b): 1 \leq a \leq b \leq M}{\operatorname{argmin}} \left(DTW(X, Y(a:b)) \right).$$

Indeksa a^* in b^* kot tudi optimalno poravnavo med X in podzaporedjem $Y(a^*: b^*)$ lahko izračunamo s prilagoditvijo inicializacije DTW algoritma opisanega v predhodnem razdelku

(6.3.2.1). Osnovna ideja je, da se ne kaznuje izpustitev začetnega in končnega dela na Y . Tako spremenimo opredelitev matrice akumuliranih cen D tako, da je $D(n, 1) = \sum_{k=1}^n c(x_k, y_1)$ za $n \in [1:N]$ in $D(1, m) = c(x_1, y_m)$ za $m \in [1:M]$. Ostale vrednosti D se izračunajo rekurzivno za $n \in [2:N]$ in $m \in [2:M]$. Podobno kot pri osnovni DTW lahko tudi tukaj poenostavimo inicializacijo z razširitvijo matrice D z dodatno vrstico in stolpcem tako, da nastavimo $D(n, 0) = \infty$ za $n \in [0:N]$, $D(0, m) = 0$ za $m \in [0:M]$. Indeks b^* določimo iz D z

$$b^* = \operatorname{argmin}_{b \in [1:M]} D(N, b).$$

Za iskanje a^* in optimalne poti sledenja med X in $Y(a^*: b^*)$ uporabimo algoritem za izračun optimalne poti sledenja p^* , vendar začnemo s $p_L = (N, b^*)$. Če je $p^* = (p_1, \dots, p_L)$ najdena pot, potem je $a^* \in [1:M]$ največji indeks tako, da je $p_l = (a^*, 1)$ za en $l \in [1:L]$. Torej, vsi elementi iz Y levo od y_{a^*} in desno od y_{b^*} se ne upoštevajo in zato ne doprinesejo k skupni ceni. Optimalna pot sledenja med X in $Y(a^*: b^*)$ je podana s (p_1, \dots, p_L) . Očitno je časovna kompleksnost algoritma DTW za iskanje podzaporedij enaka $O(NM)$. Optimalno podzaporedje $Y(a^*: b^*)$ v splošnem ni unikatno opredeljeno. Zato imamo lahko več rešitev za b^* .

Sledi opis uporabe matrice akumuliranih cen D za iskanje vseh podzaporedij v Y , ki so dovolj podobna podzaporedju X glede na DTW razdaljo. Opredelimo funkcijo razdalje

$$\Delta: [1:M] \rightarrow \mathbb{R}, \quad \Delta(b) = D(N, b).$$

Ta vsakemu indeksu $b \in [1:M]$ dodeli najmanjšo DTW razdaljo $\Delta(b)$, ki je lahko dosežena med X in podzaporedjem $Y(a:b)$ iz Y in se konča z y_b . Za vsak $b \in [1:M]$ lahko izračunamo $a \in [1:M]$ analogno izračunu a^* z uporabo algoritma za izračun optimalne poti sledenja in z začetkom v $p_L = (N, b)$. Če je $\Delta(b)$ majhen za nekatere $b \in [1:M]$ in če je $a \in [1:M]$ ustrezen indeks, potem je podzaporedje $Y(a:b)$ blizu X .

Algoritem za izračun podzaporedij Y , ki so blizu X :

- Vhod sestavljajo iskano zaporedje $X = (x_1, x_2, \dots, x_N)$, preiskovano zaporedje $Y = (y_1, y_2, \dots, y_M)$ in prag cene $\tau \in \mathbb{R}$.
 - Izhod je prednostni seznam vseh različnih podzaporedij iz Y , ki imajo DTW razdaljo do X pod pragom τ .
 - α je ustrezna okolica okrog b^* .
- (1) Inicializiramo (izpraznimo) prednostni seznam.
 - (2) Izračunamo matriko akumuliranih cen D iz X in Y .
 - (3) Določimo funkcijo razdalje Δ .

- (4) Določimo najmanjšo $b^* \in [1: M]$ iz Δ .
- (5) Če $\Delta(b^*) > \tau$, potem končamo postopek.
- (6) Izračunamo ustrezen indeks $a^* \in [1: M]$.
- (7) Na prednostni list dodamo podzaporedje $Y(a^*: b^*)$.
- (8) Nastavimo $\Delta(b) = \infty$ za vse b znotraj α okolice b^* .
- (9) Skočimo na korak 4.

Da se prepreči generiranje rešitev, ki se razlikujejo samo v majhnih časovnih zamikih, se v koraku (7) odstrani celotna okolica b^* iz nadaljnje obdelave. Glede na aplikacijo se lahko bodisi izbere fiksna širina okolice bodisi se ta določi glede na lokalne značilnosti Δ okrog b^* .

6.3.2.3 Podroben opis nove metode za odstranjevanje EKG motnje iz EMG signala

V tem razdelku bomo opisali nov pristop za odstranjevanje EKG motnje iz EMG signala, ki je primeren za avtomatsko obdelavo EMG signalov. Postopek odstranjevanja EKG motnje je sestavljen iz več manj ali bolj kompleksnih korakov. Tukaj je podan kratek opis korakov postopka, kateremu sledi podrobnejši opis vsakega koraka posebej.

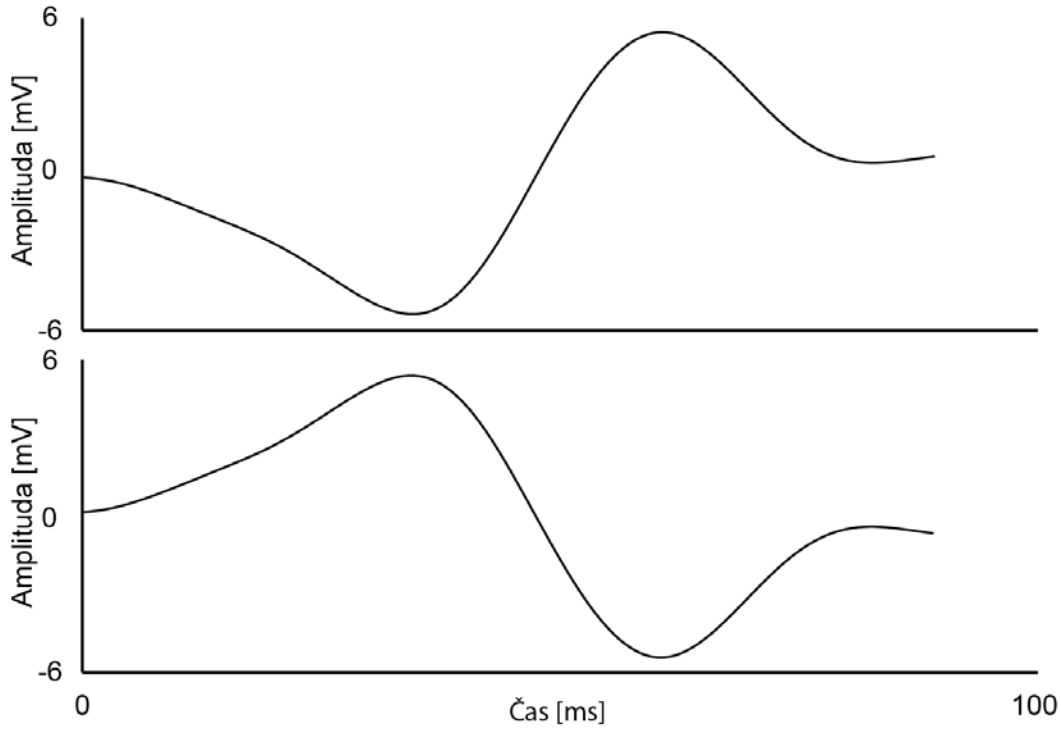
- Vhodni podatki so EMG signal, EKG predloge in najmanjša sprejemljiva ocena zanesljivosti zaznave (EKG_{omin}).
 - Izhod je EMG signal brez EKG motnje.
- (1) EMG signal filtriramo z Butterworth pasovno prepustnim filtrom s prepustnim pasom med 3 in 20 Hz ter stopnjo 2.
 - (2) S pristopom za iskanje podzaporedij (vzorcev) z dinamičnim časovnim sledenjem (DTWS) poiščemo vse kandidate za EKG artefakt.
 - (3) Iz množice EKG kandidatov izberemo tiste, ki se pojavijo v začetnem delu EMG signala, kjer aktivacija mišice ni prisotna.
 - (4) Iz izbranih EKG kandidatov (iz koraka 3) izberemo tiste, ki najboljše predstavljajo EKG artefakte (EKG_{pred}) in hkrati upoštevamo potencialno manjkajoče kandidate. Pri tem uporabimo širino artefakta in cikel.
 - (5) Za manjkajoče EKG artefakte iz prejšnjega koraka poiščemo najustreznejše kandidate na pričakovanem časovnem intervalu. Za iskanje uporabimo DTWS algoritem oziroma samo algoritem za iskanje optimalne poti sledenja. Najdene EKG kandidate dodamo v množico EKG_{pred}.

- (6) V množico EKGpred dodamo EKG kandidate, ki se pojavijo v drugem delu EMG signala (kjer je prisotna mišična aktivacija), in tako dobimo množico EKG kandidatov EKGvsi.
- (7) Iz EKGvsi izberemo tiste, ki najboljše predstavljajo EKG artefakte in hkrati upoštevamo potencialno manjkajoče kandidate. Pri tem se uporabimo širino artefakta in cikel.
- (8) Za manjkajoče EKG artefakte iz prejšnjega koraka poiščemo najustreznejše kandidate na pričakovanem časovnem intervalu. Za iskanje uporabimo DTWS algoritem oziroma samo algoritem za iskanje optimalne poti sledenja. Najdene EKG kandidate dodamo v množico EKGvsi.
- (9) Izračunamo oceno zanesljivosti zaznave EKG motnje v EMG signalu (EKGo).
- (10) Če je EKGo večja ali enaka EKGomin, od izvirnega EMG signala odštejemo signal, ki ga dobimo s filtracijo v koraku (1), vendar samo na intervalih, kjer so prisotni EKG artefakti iz množice EKGvsi.


Korak (1). Vemo, da se frekvenčna spektra EKG in EMG signala delno prekrivata. Frekvenčni razpon EKG spektra se razteza od 1 do 75 Hz (Zhan idr., 2010), vendar je večina energije prisotna v razponu med 1 in 20 Hz (Lin, 2008). Na drugi strani je frekvenčni razpon EMG spektra med 0 in 500 Hz (De Luca, 1997). Na podlagi teh dejstev zaključimo, da moramo obravnavati samo frekvenčno območje, kjer se oba spektra prekrivata, to je med 1 in 20 Hz. Izkaže se, da EMG signal pod 20 Hz vsebuje relativno malo energije, zato EKG artefakti pridejo bolj do izraza v časovni domeni. Za ločevanje frekvenčnega spektra EMG signala pod 20 Hz smo uporabili Butterworth pasovno prepustni filter s prepustnim pasom med 3 in 20 Hz ter stopnjo 2. Razlog za spodnjo mejo pri 3 Hz je opisan v razdelku 6.2.

Korak (2). EKG artefakti imajo lahko različne vzorce, vendar se ti ne spreminjajo naključno. To pomeni, da je vzorec EKG artefakta približno enak med meritvijo ene mišice. Različne mišice imajo v osnovi dva vzorca, ki sta med seboj zrcaljena preko časovne osi (Slika 6.8). To je posledica odčitavanja potenciala napetosti med dvema elektrodama. Vzorci EKG artefaktov se nelinearno razlikujejo v amplitudi in času. Te razlike se pojavljajo tako med preiskovanci kot tudi med zajemi na različnih mišicah enega preiskovanca (Slika 6.9).

Slika 6.8: Primer predloge prezrcaljene preko časovne osi.



Slika 6.9: Primer variabilnost EKG artefakta za tri različne preiskovance.



Na podlagi navedenega smo zaključili, da je metoda DTWS primerna za iskanje EKG artefaktov v EMG signalu, ki je obdelan na način, opisan v koraku (1). Za iskanje kandidatov za EKG artefakte uporabimo izvedenko algoritma DTWS, ki uporablja lokalne uteži, in predloge, ki so podane kot vhodni parameter metode. Z utežmi se favorizira vertikalno smer iskanja in s tem

izločimo primere, ko bi lahko prišlo do neželenega podaljševanja najdenega EKG vzorca v levo ali desno. Do podaljševanja v levo ali desno pride takrat, ko so vrednosti EMG signala levo/desno od potencialnega kandidata blizu vrednostim začetne/končne vrednosti predloge. Nastavitve DTWS, ki se uporabljajo za iskanje EKG artefaktov so: lokalne uteži $(w_v, w_h, w_d) = (20, 1, 1)$, prag τ se določi adaptivno na 0,05 percentil DTW razdalje, okolica α je 200 ms. Prag τ omeji izbor možnih vzorcev na 5 % tistih kandidatov, ki so najbližje predlogi. Hkrati adaptivni prag omogoča iskanje vzorcev, ki različno odstopajo od amplitude predloge in so znotraj meritve konsistentni. Z okolico α se omeji generiranje vzorcev, ki se kvečjemu malo razlikujejo v času in gre zato dejansko za isti EKG artefakt.

Ker uporabimo več predlog za iskanje vzorcev, dobimo tudi več funkcij DTW razdalje. Za nadaljnje iskanje vzorcev se uporabi tista funkcija DTW razdalje, ki ima manjše ekstremne vrednosti pod pragom 0,05 percentil DTW razdalje in je zato najbolj podobna predlogi. Na izbrani funkciji DTW razdalje uporabimo algoritem za izračun optimalne poti sledenja in tako dobimo kandidate za EKG artefakte.

Korak (3). Iz množice kandidatov EKG artefaktov izberemo tiste, ki se pojavijo v začetnem delu EMG signala, kjer ni mišične aktivacije. Tako dobimo množico kandidatov, ki je zanesljivejša kot množica, ki vsebuje tudi kandidate iz dela EMG signala, kjer je prisotna mišična aktivacija. Priporočljiva dolžina dela EMG signala, kjer ni mišične aktivacije, je 5 s. S tem zagotovimo prisotnost približno štirih do šestih EKG artefaktov.

Korak (4). Ker je lahko tudi kakšen del EMG signala podoben EKG artefaktu, se lahko v množici kandidatov EKG artefaktov pojavijo neprimerni kandidati. Ta problem rešimo z uporabo znanih lastnosti EKG-ja (širina artefakta in cikel ponavljanja). Najprej odstranimo kandidate, kateri so ožji od 40 ms in širši od 150 ms. Nato iz množice kandidatov sestavimo vse možne kombinacije cikla EKG-ja in izberemo tisto kombinacijo, ki vsebuje največ EKG kandidatov ter ima hkrati najmanj manjkajočih kandidatov. Če je takšnih kombinacij več, izberemo tisto, ki ima manjšo povprečno DTW razdaljo. Za manjkajoče kandidate izračunamo pričakovano točko začetka EKG artefakta kot srednjo vrednost med sosednjima EKG artefaktoma.

Korak (5). Za manjkajoče EKG artefakte iz prejšnjega koraka poiščemo najustreznejše kandidate na pričakovanem časovnem intervalu. Za iskanje uporabimo DTWS algoritem oziroma samo algoritem za iskanje optimalne poti sledenja. Prag τ nastavimo na 0,10 percentil DTW razdalje zato, da poiščemo kandidata tudi v primeru, ko se ta nekoliko bolj razlikuje od predloge. Pričakovan časoven interval nastavimo na podlagi povprečne širine EKG kandidatov

iz predhodnega koraka, in sicer na dvakratno povprečno širino okrog pričakovane točke začetka EKG artefakta. Najdene EKG kandidate dodamo v množico EKGpred.

Korak (6). V množico EKGpred dodamo EKG kandidate, ki se pojavijo v drugem delu EMG signala (kjer je prisotna mišična aktivacija), in dobimo množico EKG kandidatov EKGvsi.

Korak (7). Iz EKGvsi izberemo tiste, ki najboljše predstavljajo EKG artefakte in pri tem upoštevamo potencialno manjkajoče kandidate. Postopek v tem koraku je enak postopku v koraku (4).

Korak (8). Za manjkajoče EKG artefakte iz prejšnjega koraka poiščemo najustreznejše kandidate na pričakovanem časovnem intervalu. Postopek v tem koraku je enak postopku v koraku (5). Najdene kandidate dodamo v množico EKGvsi.

Korak (9). Izračunamo oceno zanesljivosti zaznave EKG motnje v EMG signalu (EKGo). EKGo dobimo kot razmerje med DTW razdaljo kandidatov iz EKGpred in DTW razdaljo »ostalega dela« EMG signala, kjer ni mišične aktivacije. DTW razdaljo »ostalega dela« EMG signala dobimo tako, da izračunamo razliko med 0,20 percentil DTW razdalje in 0,90 percentil DTW razdalje. Meji 0,20 in 0,90 smo določili na podlagi analize funkcije DTW razdalje, ko je prisotna EKG motnja. V tem primeru je na tem območju večina vrednosti DTW razdalje. DTW razdaljo kandidatov iz EKGpred dobimo tako, da izračunamo razliko med povprečjem minimumov DTW razdalje za vse kandidate iz EKGpred in 0,90 percentil DTW razdalje na intervalu, kjer ni mišične aktivacije. EKGo izračunamo kot razmerje med DTW razdaljo kandidatov iz EKGpred in DTW razdaljo »ostalega dela« EMG signala.

Korak (10). Na koncu preverimo, ali je EKGo večja ali enaka EKGomin, torej ali EMG signal vsebuje EKG motnjo. Če jo, potem od izvirnega EMG signala odštejemo signal, ki ga dobimo s filtracijo v koraku (1), vendar samo na intervalih, kjer so prisotni EKG artefakti iz množice EKGvsi. Tako dobimo EMG signal, iz katerega smo odstranili EKG artefakte.

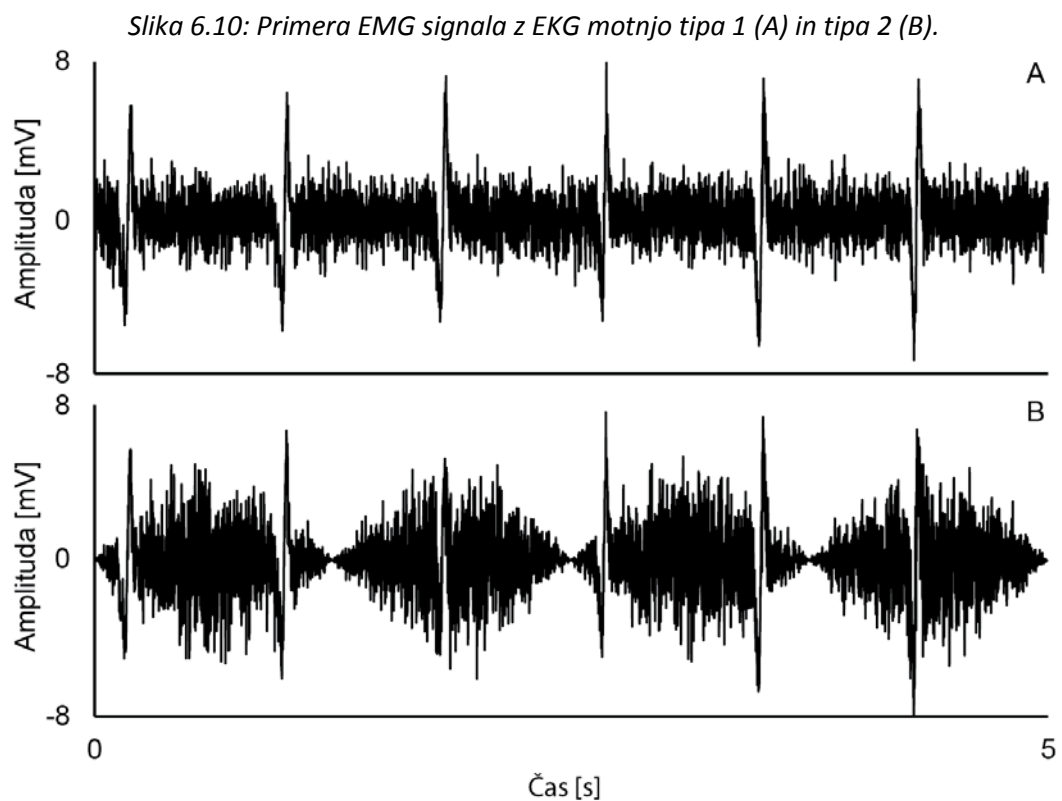
6.3.3 Vrednotenje nove metode za odstranjevanje EKG motnje iz EMG signala

Uspešnost metode za odstranjevanje EKG motnje iz EMG signala smo ovrednotili na umetno ustvarjenih primerih EMG signalov in na realnih EMG signalih. Oboji signali so vsebovali primere z EKG motnjo kot tudi primere brez EKG motnje. Za vrednotenje na umetno

ustvarjenih signalih smo se odločili, ker pri realnih EMG signalih z EKG motnjo ne moremo natančno izračunati uspešnosti metode, saj ne vemo, kakšna sta dejanska izvorna EMG in EKG signala. Signale smo uporabili za ovrednotenje uspešnosti predlagane metode na dva načina. Najprej smo ovrednotili uspešnost zaznavanja prisotnosti EKG motnje v EMG signalu. Nato smo ovrednotili uspešnost odstranjevanja EKG artefaktov iz EMG signala.

6.3.3.1 Vrednotenje uspešnosti predlagane metode na umetno ustvarjenih EMG signalih

Vrednotenje z uporabo umetno ustvarjenih EMG signalov se je pogosto uporabljalo v literaturi (Lu idr., 2009; Mak idr., 2010; Taelman idr., 2011; Zhan idr., 2010). Umetno ustvarjene EMG signale smo naredili s kombinacijo umetno narejenega EMG signala in realnega EKG signala. Umetno narejen EMG signal smo ustvarili z Gaussovimi belimi šumi, ki je imel povprečno vrednost enako nič. Naredili smo 10 primerov takšnih signalov in jih poimenovali s tip 1. Nato smo vseh 10 primerov modulirali s kosinusno funkcijo in tako dobili dinamične signale, ki so simulirali aktivacijo mišic. Poimenovali smo jih s tip 2. Na koncu smo vsem 10-im primerom vsakega tipa (Slika 6.10) prišteli različne EKG signale in dobili množico 40 primerov umetno ustvarjenih EMG signalov z in brez EKG motnje. Realne EKG signale smo pridobili iz naše baze raziskovalnih meritev.



Uspešnost zaznavanja prisotnosti EKG motnje v EMG signalu predlagane metode smo ocenili z odstotkom pravilno prepoznanih EMG signalov z in brez EKG motnje (klasifikacijsko točnostjo (KT)) ter s statističnima merama občutljivosti in specifičnosti (podroben opis metod je v razdelku 3.1.4). V našem primeru je občutljivost odstotek EMG signalov, ki vsebujejo EKG motnjo, in so pravilno prepoznani kot takšni. Na drugi strani je specifičnost odstotek EMG signalov, ki ne vsebujejo EKG motnje, in so pravilno prepoznani kot takšni.

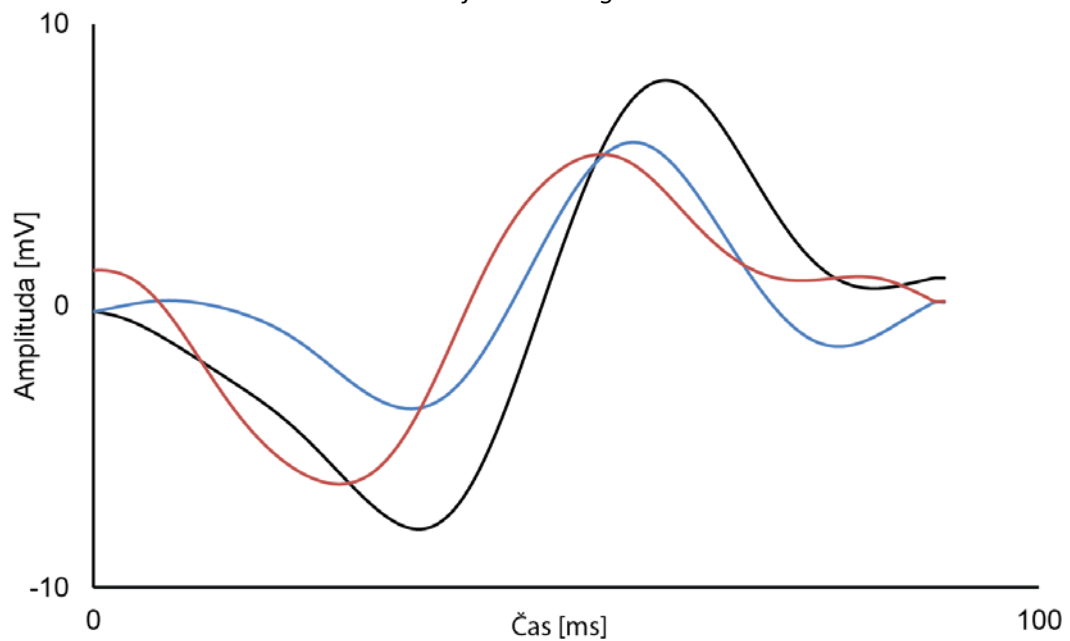
Uspešnost odstranjevanja EKG motnje iz EMG signala smo ovrednotili z dveh vidikov: frekvenčnega in amplitudnega. S pomočjo analize močnostnega spektra, ki je pogosto uporabljena metoda za kvantitativno analizo EMG signala (Bartolo idr., 1996; Zhan idr., 2010), smo ocenili uspešnost odstranjevanja frekvenc EKG motnje. Pri tem smo uporabili mero relativne napake (δ), ki je določena kot

$$\delta = \frac{\sum_n (P_n - \tilde{P}_n)^2}{\sum_n P_n^2} * 100 \%,$$

kjer je P močnostni spekter umetnega EMG signala brez EKG motnje, \tilde{P} močnostni spekter očiščenega EMG signala in n frekvenca močnostnega spektra. Amplitudno razliko med umetnim EMG signalom brez EKG motnje in očiščenim EMG signalom smo ocenili kot razliko med korenoma povprečja kvadratov (RMSr) obeh signalov.

V sklopu vrednotenja uspešnosti predlagane metode na umetnih EMG signalih smo preverili tudi vpliv izbire različnih predlog za iskanje EKG artefaktov. Uporabili smo tri predloge (Slika 6.11), ki so med seboj različne po amplitudi in časovni zamaknjenosti. Predloge smo pridobili iz realnih EKG signalov, ki so bili filtrirani z Butterworth pasovno prepustnim filtrom s prepustnim pasom med 3 in 20 Hz ter stopnjo 2. Da smo zagotovili nepristranskost vrednotenja, smo predloge pridobili iz EKG signalov, ki niso bili uporabljeni za ustvarjanje testnih primerov. Predlagano metodo smo uporabili z vsako predlogo posebej na vsakem primeru testne množice.

Slika 6.11: Predloge, uporabljene za testiranje uspešnosti nove metode za odstranjevanje EKG motnje iz EMG signala.



Predlagana metoda je v vseh primerih iz testne množice pravilno določila ali je/ni prisotna EKG motnja v EMG signalu. Pri obeh tipih umetno ustvarjenih EMG signalov je dosegla 100 % KT za vsako od treh predlog in posledično tudi 100 % občutljivosti in 100 % specifičnost. Uporaba različnih predlog ni vplivala na rezultate.

Tabela 6.1: Rezultati vrednotenja uspešnosti odstranjevanje EKG motnje iz EMG signala na umetno ustvarjenih EMG signalih.

| Tip | Predloga | δ [%] | RMSr [mV] |
|----------|----------|--------------|---------------|
| 1 | 1 | 1,41 (0,13) | 0,003 (0,006) |
| | 2 | 1,39 (0,12) | 0,004 (0,004) |
| | 3 | 1,43 (0,13) | 0,002 (0,003) |
| 2 | 1 | 1,26 (0,13) | 0,014 (0,011) |
| | 2 | 1,27 (0,11) | 0,011 (0,008) |
| | 3 | 1,29 (0,14) | 0,004 (0,005) |

Vrednosti so zapisane kot povprečna vrednost (SD).

Rezultati vrednotenja uspešnosti odstranjevanja EKG motnje iz EMG signala s predlagano metodo na umetno ustvarjenih EMG signalih so predstavljeni v Tabeli 6.1. Med tremi predlogami za oba tipa testnih signalov ni bistvenih razlik v δ in RMSr. Povprečna RMSr za tip 1 je za vse tri predloge zelo blizu 0. Zelo majhna razlika v RMSr je tudi za tip 2. Razlika povprečne

δ med predlogami je nekoliko večja, vendar še zmeraj pod 1,5 % (med 1,39 in 1,43 % za tip 1 in med 1,26 in 1,29 % za tip 2).

6.3.3.2 Vrednotenje uspešnosti predlagane metode na realnih EMG signalih

Množica realnih EMG signalov, na kateri smo ovrednotili uspešnost predlagane metode, je vsebovala EMG signale treh preiskovancev. Vsak preiskovanec (P1, P2 in P3) je imel podatke za 9 mišic, dve nalogi in med 15 in 20 ponovitev naloge. Torej smo imeli skupno 981 primerov, od katerih je 386 primerov vsebovalo EKG motnjo. Za vsak primer iz opisane množice realnih EMG signalov sta dva izkušena eksperta za EMG analizo določila, ali primer vsebuje EKG motnjo ali ne. Tako označeno testno množico smo nato uporabili za vrednotenje uspešnosti predlagane metode.

Uspešnost zaznavanja prisotnosti EKG motnje v EMG signalu predlagane metode smo ovrednotili enako kot na množici umetnih EMG signalov. Torej s KT ter občutljivostjo in specifičnostjo. Predlagana metoda izračuna tudi EKGo, ki je ocena verjetnosti, da EMG signal vsebuje EKG motnjo. Na podlagi te analize smo določili optimalno EKGo, ki smo jo uporabili pri nadaljnjih analizah. Za EKGo smo izračunali naslednje statistike: EKGo-POV – povprečna vrednost EKGo, EKGo-SD – SD EKGo, EKGo-MIN – najmanjša vrednost EKGo in EKGo-MAKS – največja vrednost EKGo. EKGo_{min} smo nastavili na 2,5, kar pomeni, da je bil to spodnji prag zaznave EKG motnje. Analizo smo naredili za vsakega preiskovanca posebej in za vsako mišico posebej, ker je moč EKG motnje različna tako med preiskovanci kot tudi med mišicami na enem preiskovancu.

Vrednotenje uspešnosti odstranjevanja EKG motnje iz EMG signala je na realnih signalih bolj problematično v primerjavi z umetnimi EMG signali, saj ne vemo, kakšen je dejanski izvorni EMG signal. Za vrednotenje smo ponovno uporabili močnostni spekter, iz katerega smo izračunali parametra, ki sta se pogosto uporabljala v literaturi (Zhan idr., 2010): razmerje med visoko in nizko frekvenco (V/N) in povprečna frekvenca (F). V/N je razmerje med močjo frekvenčnega območja med 125 in 150 Hz ter močjo frekvenčnega območja med 0 in 25 Hz izraženo v odstotkih. F je

$$F = \frac{\sum_n n * P_n}{\sum_n P_n},$$

kjer je P močnostni spekter obdelanega EMG signala brez EKG motnje in n frekvenca močnostnega spektra. Analizo smo naredili samo na primerih, kjer je bila zaznana EKG motnja,

in sicer za vsakega preiskovanca in vsako mišico posebej. Uspešnost odstranjevanja EKG motnje iz EMG signala s predlagano metodo smo primerjali z visoko prepustnim filtrom (VPF), ki je bil v določenih problemih v literaturi predlagan kot najoptimalnejša metoda za odstranjevanje EKG motnje (Drake & Callaghan, 2006; Zhou idr., 2005). Uporabili smo Butterworth visokoprepustni filter s prepustnim pasom nad 30 Hz ter stopnjo 2.

Tabela 6.2 prikazuje rezultate testiranja zaznave EKG motnje v EMG signalu. Mišice DA, MF-L in OI niso vsebovale primera z EKG motnjo pri nobenem preiskovancu. V teh primerih je bila predlagana metoda popolnoma zanesljiva (KT je bila 100 %) razen v primeru mišice OI pri P3, kjer je bila KT 97 %. Posledično je bila tudi specifičnost 100 %, saj so bili vsi primeri brez EKG motnje prepoznani kot takšni. V primeru OI pri P3 je bila EKGo-POV 2,53, kar je komaj nad spodnjim pragom EKGo-min. MF-R je bila onesnažena z EKG motnjo samo pri P3, kjer je 21 od 38 primerov vsebovalo EKG artefakte. Zaznava EKG motnje je bila 97 % pri občutljivosti 100 % in specifičnosti 94 % ter EKGo-POV 3,12 za prepoznane EKG artefakte. ES-L in ES-R sta vsebovali EKG motnjo pri P1 in P3. Pri P3 so bili onesnaženi vsi primeri obeh mišic, medtem ko je bilo pri P1 onesnaženih 13 od 35 primerov pri ES-L in 19 od 35 primerov pri ES-R. Zaznava EKG motnje pri P3 za obe mišici je bila popolna (KT in občutljivost sta bile 100 %) pri visoki EKGo-POV (4,74 pri ES-L in 4,56 pri ES-R). Na drugi strani je bila zaznava prisotnosti EKG motnje slabša pri P1 za obe mišici, še posebej pri ES-L (KT = 86 %, občutljivost = 86 %, EKGo-POV = 2,70). OE-L ni vsebovala EKG motnje pri P3, medtem ko so vsi primeri pri P1 in P2 vsebovali motnjo. Zaznava EKG motnje je bila popolna pri P1 in P2 z visoko EKGo-POV (3,73 pri P1 in 5,28 pri P2). Pri P3 je bila zaznava slabša, saj je bila specifičnost 95 % z EKGo-POV 2,75 pri napačno prepoznanih EKG artefaktih. OE-R je vsebovala EKG motnjo pri vseh treh preiskovancih, od katerih so jo samo pri P2 vsebovali vsi primeri. Samo pri P2 je bila zaznava EKG motnje popolna z EKGo-POV 3,94, medtem ko je bila zaznava slabša pri P1 (KT = 97 %, občutljivost = 97 %, specifičnost = 89 %, EKGo-POV = 2,86) in pri P2 (KT = 92 %, občutljivost = 80 %, specifičnost = 100 %, EKGo-POV = 2,66). RA je bila edina mišica, pri kateri so vsi primeri pri vseh treh preiskovancih vsebovali EKG motnjo. Tukaj je bila zaznava EKG motnje popolna z EKGo-POV večjo od 3,39 za vse preiskovance. Če povzamemo uspešnost zaznave EKG motnje pri vseh mišicah za vse preiskovance skupaj, vidimo, da je zaznava zelo uspešna (KT \geq 97 %) pri vrednosti EKGo-POV nad 3.

Tabela 6.2: Rezultati testiranja zaznave EKG motnje v EMG signalu na realnih signalih.

| Mišica | Preiskovanec | EKG / VSI | KT [%] | Obč [%] | Spec [%] | EKGo-POV | EKGo-SD | EKGo-MIN | EKGo-MAKS |
|--------|--------------|-----------|--------|---------|----------|----------|---------|----------|-----------|
| DA | P1 | 0 / 35 | 100 | / | 100 | / | / | / | / |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 0 / 38 | 100 | / | 100 | / | / | / | / |
| ES-L | P1 | 13 / 35 | 86 | 77 | 91 | 2,70 | 0,20 | 2,37 | 3,06 |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 38 / 38 | 100 | 100 | / | 4,74 | 0,64 | 3,35 | 5,83 |
| ES-R | P1 | 19 / 35 | 97 | 95 | 100 | 3,07 | 0,33 | 2,61 | 3,96 |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 38 / 38 | 100 | 100 | / | 4,56 | 0,65 | 3,33 | 6,01 |
| MF-L | P1 | 0 / 35 | 100 | / | 100 | / | / | / | / |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 0 / 38 | 100 | / | 100 | / | / | / | / |
| MF-R | P1 | 0 / 35 | 100 | / | 100 | / | / | / | / |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 21 / 38 | 97 | 100 | 94 | 3,12 | 0,36 | 2,64 | 3,87 |
| OI | P1 | 0 / 35 | 100 | / | 100 | / | / | / | / |
| | P2 | 0 / 36 | 100 | / | 100 | / | / | / | / |
| | P3 | 0 / 38 | 97 | / | 97 | 2,53 | / | 2,53 | 2,53 |
| OE-L | P1 | 35 / 35 | 100 | 100 | / | 3,73 | 0,39 | 2,88 | 4,64 |
| | P2 | 36 / 36 | 100 | 100 | / | 5,28 | 0,60 | 4,00 | 6,33 |
| | P3 | 0 / 38 | 95 | / | 95 | 2,75 | 0,25 | 2,57 | 2,93 |
| OE-R | P1 | 26 / 35 | 97 | 100 | 89 | 2,86 | 0,26 | 2,55 | 3,54 |
| | P2 | 36 / 36 | 100 | 100 | / | 3,94 | 0,38 | 3,03 | 4,70 |
| | P3 | 15 / 38 | 92 | 80 | 100 | 2,66 | 0,10 | 2,54 | 2,84 |
| RA | P1 | 35 / 35 | 100 | 100 | / | 4,42 | 0,70 | 3,19 | 6,81 |
| | P2 | 36 / 36 | 100 | 100 | / | 3,64 | 0,38 | 2,92 | 4,31 |
| | P3 | 38 / 38 | 100 | 100 | / | 3,39 | 0,42 | 2,63 | 4,38 |

EKG / VSI – število primerov z EKG motnjo / vsi primeri, KT – klasifikacijska točnost, Obč – občutljivost, Spec – specifičnost, EKGo-POV – povprečna vrednost EKGo, EKGo-SD – SD EKGo, EKGo-MIN – najmanjša vrednost EKGo in EKGo-MAKS – največja vrednost EKGo.

V Tabeli 6.3 so prikazani rezultati testiranja uspešnosti odstranjevanja EKG motnje iz EMG signala ter primerjava uspešnosti z VPF. Če primerjamo V/N in F med izvornim EMG signalom, obdelanim EMG signalom s predlagano metodo in obdelanim EMG signalom z VPF, opazimo, da sta V/N in F najmanjša pri izvornem EMG signalu, srednja pri obdelanem EMG signalu s predlagano metodo in največja pri obdelanem EMG signalu z VPF. Ker izvorni EMG signal vsebuje EKG motnje, ki večinoma vsebujejo frekvence pod 20 Hz, je pričakovano, da sta V/N in F manjša kot pri obdelanem EMG signalu s predlagano metodo in z VPF. VPF odstrani

frekvence pod 30 Hz na celotnem EMG signalu, medtem ko predlagana metoda odstrani nizke frekvence le na delih, kjer so prisotni EKG artefakti. Torej je pričakovano, da sta V/N in F najmanjša pri obdelanem EMG signalu s predlagano metodo v primerjavi z obdelanim EMG signalom z VPF. Zaključimo lahko, da je odstranjevanje s predlagano metodo v vseh primerih odstranilo del EMG signala z nizko frekvenco (v območju kjer je EKG signal), vendar je hkrati odstranilo precej manj signala kot VPF.

Tabela 6.3: Rezultati testiranja uspešnosti odstranjevanja EKG motnje iz EMG signala na realnih signalih.

| Mišica | Parameter | P1 | | | P2 | | | P3 | | |
|--------|-----------|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| | | Izv | Obd | Vpf | Izv | Obd | Vpf | Izv | Obd | Vpf |
| DA | V/N [%] | - | - | - | - | - | - | - | - | - |
| | F [Hz] | - | - | - | - | - | - | - | - | - |
| ES-L | V/N [%] | 4 | 11 | 49 | - | - | - | 4 | 17 | 54 |
| | F [Hz] | 61 | 85 | 103 | - | - | - | 67 | 119 | 133 |
| ES-R | V/N [%] | 4 | 14 | 53 | - | - | - | 2 | 14 | 25 |
| | F [Hz] | 60 | 92 | 112 | - | - | - | 49 | 125 | 134 |
| MF-L | V/N [%] | - | - | - | - | - | - | - | - | - |
| | F [Hz] | - | - | - | - | - | - | - | - | - |
| MF-R | V/N [%] | - | - | - | - | - | - | 64 | 126 | 632 |
| | F [Hz] | - | - | - | - | - | - | 150 | 161 | 170 |
| OI | V/N [%] | - | - | - | - | - | - | 60 | 79 | 733 |
| | F [Hz] | - | - | - | - | - | - | 125 | 130 | 143 |
| OE-L | V/N [%] | 3 | 15 | 34 | 5 | 39 | 45 | 9 | 11 | 82 |
| | F [Hz] | 85 | 125 | 138 | 93 | 159 | 153 | 67 | 72 | 85 |
| OE-R | V/N [%] | 12 | 34 | 120 | 9 | 49 | 82 | 16 | 28 | 121 |
| | F [Hz] | 142 | 170 | 183 | 148 | 205 | 210 | 115 | 127 | 138 |
| RA | V/N [%] | 8 | 31 | 101 | 6 | 17 | 48 | 13 | 33 | 225 |
| | F [Hz] | 130 | 181 | 203 | 87 | 131 | 143 | 135 | 166 | 191 |

Izv – izvorni EMG signal, Obd- EMG signal obdelan s predlagano metodo in Vpf – EMG signal obdelan z VPF.

6.3.4 Razprava in zaključek


Po pregledu literature s področja odstranjevanja EKG motnje iz EMG signala smo prišli do zaključka, da nobena od predhodno uporabljenih in v literaturi poročanih metod ne ustreza zahtevam za uporabo pri avtomatski obdelavi EMG signalov. Zahteve so bile: uporaba brez posredovanja uporabnika, uporaba brez dodatno zajetega EKG signala, uporaba brez upoštevanja drugih EMG kanalov, uporaba brez znanja, pridobljenega iz učne množice ter ocena zanesljivosti zaznave EKG motnje. Nekatere metode bi lahko nadgradili tako, da bi

zadostile tem zahtevam. Vendar smo se na podlagi poročanj o uspešnosti predlaganih metod v literaturi in naših preliminarnih analiz odločili, da razvijemo novo metodo, ki bo zadostila zahtevam za avtomatsko obdelavo ter se izognila pomanjkljivostim do sedaj predlaganih metod.

V tej nalogi smo predstavili novo metodo za odstranjevanje EKG motnje iz EMG signala, ki temelji na dobro uveljavljeni metodi DTW. DTW smo uporabili za iskanje EKG artefaktov z različnimi predlogami EKG artefaktov. Na množici najdenih kandidatov za EKG artefakte smo nato naredili še dodatno analizo, ki preveri, kateri kandidati so pravi EKG artefakti ter poišče manjkajoče EKG artefakte.

Prednosti predlagane metode pred do sedaj uporabljanimi metodami je več. Prva prednost je, da predlagana metoda za razliko od drugih metod odstrani samo del EMG signala, kjer se nahaja EKG artefakt. Podobno naredi tudi metoda rezanja (glej razdelek 3.1.2), vendar potrebuje dodatno zajet EKG signal, na podlagi katerega določi lokacijo EKG artefaktov. Odstranjevanje EKG motnje z DVT in prilagodljivim pragom tudi odstrani samo del EMG signala, kjer je prisoten EKG artefakt. Vendar detekcija EKG artefakta temelji na iskanju »nenadnih« dogodkov, katerih amplituda je večja od pred nastavljenega faktorja praga. V primeru, da je EKG motnja majhna v primerjavi z EMG signalom, bo ta metoda odpovedala, saj ne bo našla »nenadnih« dogodkov (Zhou idr., 2005). Druga prednost predlagane metode je, da lahko deluje na samo enem EMG signalu. Torej ne potrebuje EMG signalov iz več različnih mišic, kot je to v primeru uporabe ICA metode. Zato jo lahko uporabimo tudi za obdelavo že narejenih meritev z EMG signalom iz samo ene mišice. Tretja prednost predlagane metode je računanje ocene zanesljivosti zaznave EKG motnje v EMG signalu. Nobena od do sedaj predlaganih metod v literaturi ne izračuna ocene zanesljivosti zaznave EKG motnje in zato ne moremo vedeti, ali je sploh prišlo do odstranjevanja EKG motnje ali ne. Ta ocena je pomembna, ker nam pove, kako zanesljiva je zaznava EKG motnje in nam lahko služi za nadaljnje odločitve pri obdelavi EMG signala. Četrta prednost predlagane metode je, da za vhodni podatek potrebuje samo predloge EKG artefaktov. Za različne predloge smo pokazali, da vplivajo relativno malo na uspešnost same metode. Zato je metoda dovolj robustna in jo lahko uporabimo za avtomatsko obdelavo EMG signalov. Zadnja prednost predlagane metode je zmožnost odstranjevanja šibke EKG motnje iz EMG signala (Slika 6.12). Ravno to je slabost tako metode DVT s prilagodljivim pragom kot tudi metode, ki temelji na kombinaciji nelinearno skaliranih valčkov in ICA metode.


Slika 6.12: Primer odstranjevanja šibke EKG motnje iz EMG signala.



(A) EMG signal z EKG motnjo. (B) EMG signal filtriran z Butterworth pasovno prepustnim filtrom s prepustnim pasom med 3 in 20 Hz ter stopnjo 2. (C) očiščen EMG signal. Z rdečimi črtami so označeni trije intervali, na katerih so bili odstranjeni EKG artefakti.

Izpostaviti velja še primer, ko EKG artefakt sovpada z začetkom mišične aktivacije (Slika 6.13). Ta primer je pomemben, ker v naslednji stopnji obdelave EMG signala iščemo začetek mišične aktivacije, ki bo napačno določen, če ne odstranimo EKG motnje. Odstranjevanje EKG artefakta v tem primeru smo preizkusili z vsemi predhodno opisanimi metodami za odstranjevanje EKG artefaktov in ugotovili, da nobena metoda ni uspela ustrezno odstraniti EKG artefakta razen nove metode (Slika 6.13). To je pomembno, ker se s tem izboljša zanesljivost iskanja začetka mišične aktivacije v primerih, ko mišična aktivacija sovpada z EKG artefaktom.

Slika 6.13: Primer odstranjevanja EKG motnje iz EMG signala za primer sovpadanja EKG artefakt z začetkom mišične aktivacije.



(A) izvoren EMG signal z EKG motnjo. (B) EMG signal filtriran z Butterworth pasovno prepustnim filtrom s prepustnim pasom med 3 in 20 Hz ter stopnjo 2. Z rdečima črtama je označen interval, na katerem je bil prepoznani EKG artefakt. (C) očiščen EMG signal, iz katerega je razvidno, da je bil odstranjen samo EKG artefakt, medtem ko se je EMG komponenta signala ohranila.

Edina slabost predlagane metode, ki jo lahko izpostavimo je, da uporablja začetni del EMG signala (v našem primeru je bil začetni del dolg 5 s), kjer ni mišične aktivacije, za določitev osnovne množice EKG artefaktov, na podlagi katere se določijo tudi EKG artefakti na drugem delu EMG signala, kjer je prisotna mišična aktivacija. V našem primeru ta pomanjkljivost ni vplivala na delovanje metode, saj je bila narava nalog (APP in PRO) takšna, da je zagotavljala opisano obliko EMG signala. Hkrati je ta pomanjkljivost predlagane metode lahko iztočnica za nadaljnji razvoj in raziskave.

Uspešnost predlagane metode smo preverili tako na umetno ustvarjenih EMG signalih z dodano EKG motnjo kot tudi na realnih EKG signalih. V obeh primerih se je predlagana metoda izkazala za zanesljivo pri zaznavi prisotnosti EKG motnje v EMG signalu kot tudi pri odstranjevanju EKG motnje iz EMG signala. Uspešnost odstranjevanja EKG motnje smo primerjali z VPF, ki je primeren za avtomatsko obdelavo EMG signalov. VPF je pričakovano odstranil precej večji del EMG signala v primerjavi s predlagano metodo. Zaključimo lahko, da je predlagana metoda primerna za avtomatsko obdelavo EMG signalov brez posebnih omejitev ali slabosti.

6.4 Iskanje začetka in konca mišične aktivacije

Proces obdelave EMG signala zelo pogosto vsebuje določitev začetka in konca mišične aktivacije (*angl. onset and offset detection*). Ta problem lahko razčlenimo na dva podproblema, ki ju moramo rešiti. Prvi problem je iskanje dogodkov mišične aktivacije, ko na EMG signalu poiščemo vse dogodke, ko je mišica aktivna. Drug problem je iskanje začetka enega dogodka, ko moramo določiti začetek in konec mišične aktivacije čimbolj natančno. Pri tej nalogi smo se poglobljeno ukvarjali z iskanjem začetka mišične aktivacije, saj smo na podlagi znanja o izvedbi nalog (APP in PRO) lahko določili »dober« interval, na katerem smo iskali začetek mišične aktivacije. Hkrati smo se osredotočili na iskanje začetka mišične aktivacije, saj je iskanje konca mišične aktivacije v večini primerov analogen problem. Zato bomo v nadaljevanju večinoma uporabljali samo izraz iskanje začetka mišične aktivacije ter pri tem imeli v mislih tudi njegovo analogno različico za iskanje konca mišične aktivacije. Poleg tega je začetek mišične aktivacije pomemben pri analizi APP in PRO meritev, medtem ko je konec mišične aktivacije nepomemben. Značilke, ki se uporabljajo za vrednotenje teh dveh nalog, se računajo le na začetnem delu mišične aktivacije (do 50 ms po začetku mišične aktivacije).


Osnovne zahteve, katerim je morala zadostiti primerna metoda za iskanje začetka mišične aktivacije, so bile: uporaba brez posredovanja uporabnika, uporaba brez upoštevanja drugih EMG kanalov, uporaba brez znanja, pridobljenega iz učne množice, ter ocena zanesljivosti najdenega začetka. S temi kriteriji smo zagotovili primernost metode za avtomatsko obdelavo EMG signalov. Natančno določanje začetka mišične aktivacije je pomembno, ker že majhne razlike včasih (nekaj ms) lahko predstavljajo razliko med normalnim stanjem in patologijo ter razliko, doseženo z intervencijo/vadbo/terapijo.

Najprej si bomo pogledali pomanjkljivosti do sedaj predlaganih metod za iskanje začetka in konca mišične aktivacije. Sledi podroben opis nove metode za iskanje začetka in konca mišične aktivacije, ki smo jo razvili v okviru te naloge. Zaključili bomo z ovrednotenjem uspešnosti nove metode in razpravo.

6.4.1 Pregled pomanjkljivosti do sedaj predlaganih metod za iskanje začetka in konca mišične aktivacije


Prva skupina metod, ki so bile predlagane v literaturi za iskanje začetka mišične aktivacije, so metode, ki temeljijo na izbiri praga. Osnovni problem vseh teh metod je, da je začetek mišične aktivacije pogojen z nekim pragom. Ta prag mora biti nastavljen dovolj visoko, da metoda ne zazna začetka aktivacije v neaktivnem delu EMG signala. Če prag nastavimo prenizko, bomo imeli ravno obraten problem. Torej takšna metoda bo že v osnovi imela neko napako, za katero ne vemo, kakšna je. Za pojasnitev lahko vzamemo dva primera mišične aktivacije, prikazana na Sliki 6.14. Prvi primer (A) prikazuje zelo hiter prirastek mišične aktivacije, medtem ko primer (B) prikazuje počasen prirastek mišične aktivacije. Za analizo smo uporabili metodo Hodges in Bui s pragom $3 \cdot SD$. V primeru (A) smo dobili relativno dober rezultat (odstopa 5 ms od dejanskega začetka), medtem ko smo v primeru (B) dobili slab rezultat (odstopa 82 ms od dejanskega začetka).

Slika 6.14: Primer iskanja začetka mišične aktivacije z metodo Hodges in Bui.



Prikazana sta dva primera mišične aktivacije: (A) zelo hiter prirastek mišične aktivacije in (B) počasen prirastek mišične aktivacije. Rdeča črta prikazuje dejanski začetek mišične aktivacije, medtem ko zelena črta prikazuje najden začetek mišične aktivacije z metodo Hodges in Bui s pragom $3 \cdot SD$.

Druga skupina metod za iskanje začetka mišične aktivacije temelji na statistično optimalni odločitvi. Metode iz te skupine temeljijo na primerjavi razmerja logaritemske verjetnosti med dvema porazdelitvama pred in po potencialnem začetku aktivacije. Začetek mišične aktivacije se določi tam, kjer pride do prehoda med tema dvema porazdelitvama. Model porazdelitve za del pred začetkom mišične aktivacije se določi na podlagi pred nastavljenega okna, tako da je okno postavljeno na delu, kjer zagotovo ni mišične aktivacije. Ravno v postavitvi tega okna je osnovni problem teh metod (metoda optimalne cenilke, AGLRstep in AGLRramp). Okno lahko na realnih EMG signal zajame del, kjer je prišlo do neke manjše predaktivnosti mišice in zato napačno določi model, kar se odrazi v napačni postavitvi začetka mišične aktivacije. Takšen primer je prikazan na Sliki 6.15. Tukaj vidimo, da je bilo okno postavljeno na delu, kjer je prisotna predaktivnost mišice. AGLRstep je to predaktivnost privzel za osnovni model in iskal točko, v kateri pride do spremembe navzgor glede na osnovni model. Zaradi tega pride do napačne določitve začetka mišične aktivacije, saj osnovni model ne odraža dejanskega stanja ob neaktivnosti mišice.



Okno, ki je postavljeno na delu, kjer pride do predaktivnosti mišice (rdeči črti) vpliva na postavitev pravilnega začetka mišične aktivacije (siva črta), ki je v tem primeru napačna (zelena črta).

Tudi nadgradnja AGLR metode s prilagodljivim pragom (Xu idr., 2013) trpi zaradi istega problema. Kljub temu da ta metoda določa prag adaptivno na podlagi razmerja med signalom in šumom, se to razmerje določi na podlagi pred nastavljenega okna. Podobno kot ostale metode, ki temeljijo na statistično optimalni odločitvi, bo tudi ta metoda v primeru slabo postavljenega okna napačno določila začetek mišične aktivacije.

Pogosto uporabljena metoda za iskanje začetka mišične aktivacije, ki je hkrati tudi precej preprosta, je metoda integriranega profila. Kot smo to že omenili v razdelku 3.1.3, je metoda nagnjena k napačnim prepoznavam začetka mišične aktivacije, kjer šibkejši mišični aktivaciji sledi močnejša aktivacija (Allison, 2003; Santello & McDonagh, 1998). Poleg tega metoda zmeraj najde začetek mišične aktivacije, ker nima mehanizma za razmejitvev, ali je aktivacija prisotna ali ne.

Problem, s katerim se soočimo pri uporabi EMD metode za iskanje začetka mišične aktivacije, je enak kot pri predhodno opisanih metodah, ki temeljijo na statistično optimalni odločitvi. Torej bo slabo postavljeno okno na neaktivnem delu EMG signala pomenilo napako pri iskanju začetka mišične aktivacije. Avtorji metode so predlagali, da to okno postavi uporabnik, kar za nas ni sprejemljivo, saj bi s tem kršili enega od kriterijev za avtomatsko obdelavo EMG signalov.

Zanimiv pristop za iskanje začetka mišične aktivacije predstavlja metoda vzorčne entropije. Ta je bila razvita z namenom, da deluje tudi na EMG signalih, ki vsebujejo EKG motnjo. Torej, metoda zatire EKG artefakte in poudari EMG aktivnost. Na tako obdelanem EMG signalu lahko potem z različnimi metodami iščemo začetke mišične aktivacije. Metoda vzorčne entropije se zato uporablja le kot predobdelava za kasnejše iskanje začetka mišične aktivacije. Problem, na

katerega naletimo, je, da popači dejanski začetek mišične aktivacije, zato ker uporablja drseče okno za izračun vzorčne entropije (podobno kot filter tekoče aritmetične sredine za glajenje signala). Na tako obdelanem EMG signalu ni mogoče pravilno določiti začetka mišične aktivacije.

6.4.2 Nova metoda za iskanje začetka in konca mišične aktivacije

V tem razdelku bomo opisali novo metodo za iskanje začetka in konca mišične aktivacije. Razvoja metode smo se lotili, ker nobena trenutno poznana metoda za iskanje začetka mišične aktivacije ni ustrezala postavljenim kriterijem za avtomatsko obdelavo EMG signalov. Na koncu bomo ovrednotili uspešnost metode in jo primerjali z ostalimi metodami za iskanje začetka mišične aktivacije.

Tukaj opisana metoda za zaznavo začetka mišične aktivacije predpostavlja, da imamo opravka z enkratno mišično aktivacijo oziroma z enim dogodkom. Zato metoda ni primerna za iskanje začetka mišične aktivacije na EMG signalu, ki ima več zaporednih mišičnih aktivacij, saj bo našla začetek mišične aktivacije samo za en dogodek, ki pa ni nujno tisti, ki nas zanima. V takšnem primeru moramo predhodno uporabiti metodo, s katero določimo, kateri dogodek v EMG signalu analiziramo in na podlagi tega določimo okno analize.

Metoda za zaznavo začetka mišične aktivacije, ki jo predlagamo, je sestavljena iz več različno kompleksnih korakov. Osnovna ideja metode je, da z uporabo razmerja SD dveh sosednjih oken izračunamo funkcijo, ki opisuje lokalne spremembe amplitude v EMG signalu. Nato na podlagi analize funkcije lokalnih sprememb amplitude v EMG signalu določimo začetek mišične aktivacije.

Funkcijo lokalnih sprememb amplitude izračunamo v dveh korakih. Najprej opredelimo EMG signal kot $X = [x_1, x_2, \dots, x_N]$, kjer je $N \in \mathbb{N}$ dolžina EMG signala, ter preiskovano okno O , ki je določeno z začetkom $z \in \mathbb{N}$ in širino $m \in \mathbb{N}$. V prvem koraku uporabimo drseče okno dolžine $a \in \mathbb{N}$ za izračun profila SD p na X . Vrednosti p izračunamo z enačbo

$$p_k = sd(X((z - a + k):(z - 1 + k)))$$

za $k \in [0:m + a - 1]$. $X(\alpha:\beta)$ je zaprti interval med $\alpha \in \mathbb{N}$ in $\beta \in \mathbb{N}$ ter velja $\alpha < \beta$, medtem ko je $sd(Z)$ funkcija SD vektorja vrednosti Z . Za izračun p uporabimo vrednosti iz X na intervalu med $z - a$ in $z + m + a - 2$, kot to sledi iz enačbe za izračun p_k . Da preprečimo uporabo neveljavnih vrednosti iz X , mora veljati $z \geq a$ in $z + m + a - 2 \leq N$. Če eden od teh

pogojev ne drži, je potrebno ustrezno spremeniti vsaj eno od spremenljivk z , m ali a . Sedaj lahko zapišemo $p = [p_{z-a}, p_{z-a+1}, \dots, p_{z+m-1}]$, kjer en element predstavlja SD na oknu z začetkom v p_k in dolžino m . Iz enačbe za izračun p_k sledi, da za izračun p potrebujemo vrednosti iz X , ki so tudi izven okna O . Razlog za to je pojasnjen v opisu drugega koraka.

V drugem koraku izračunamo funkcijo lokalnih sprememb amplitude $q = [q_z, q_{z+1}, \dots, q_{z+m-1}]$, tako da izračunamo razmerja med SD-ji vseh sosednjih oken dolžine m na O . Dve okni sta sosednji, če je zadnji element levega okna neposredni predhodnik prvega elementa desnega okna. Razmerje SD-jev dveh sosednjih oken opredelimo kot *SD desnega okna/SD levega okna*. Za to razmerje velja, da če je SD desnega okna večje od SD levega okna, bo razmerje večje od 1 in obratno. Vrednosti q izračunamo iz p z enačbo

$$q_{z+k} = \frac{p_{z+k}}{p_{z-a+k}}$$

za $k \in [0:m-1]$. Iz te enačbe sledi, da vrednost q za trenutno časovno točko izračunamo tako, da vzamemo vrednost iz p za trenutno časovno točko in jo delimo z vrednostjo iz p za a pred trenutno časovno točko. Če želimo izračunati q za časovno točko v z , vzamemo p_z in jo delimo z p_{z-a} . Iz tega sledi, da moramo p izračunati od časovne točke $z - a$ naprej.

Funkcijo q opišemo z naslednjimi lastnostmi:


- Je funkcija lokalnih sprememb amplitude v signalu.
- »Lokalnost« določa širina drsečega okna a .
- Vrednosti q odražajo lokalno spremembo amplitude desnega okna glede na levo okno, ko sta levo in desno okno sosednji.
- Recipročna vrednost funkcije q je funkcija lokalnih sprememb amplitude levega okna glede na desno okno, ko sta levo in desno okno sosednji.

Pri izračunu funkcije q se lahko pojavi problem, ko je imenovalac enačbe za izračun q blizu nič v primerjavi z največjo vrednostjo p . V tem primeru bodo majhne absolutne spremembe imenovalca povzročile velike spremembe vrednosti q . Temu se želimo v našem primeru izogniti, saj bi to vodilo k precenitvi sprememb amplitude, ki je posledica majhne SD v imenovalcu enačbe za izračun q . Ta problem rešimo tako, da uvedemo najmanjši relativen prag p_{minSD} za vrednosti v imenovalcu, ki ga izračunamo kot $p_{minSD} = \max(p) * P_{SD}$, kjer je $\max(x)$ največja vrednost na x in P_{SD} konstanta, katero določi uporabnik. S P_{SD} uporabnik določa občutljivost funkcije q na majhne absolutne spremembe blizu vrednosti 0 v amplitudi X . Sedaj lahko zapišimo enačbo za izračun q kot

$$q_k = \frac{p_{z+k}}{\max(p_{z-a+k}, p_{\min SD})},$$

kjer je sedaj v imenovalcu spodnja vrednost omejena s $p_{\min SD}$. Primer izračuna funkcij p in q za EMG signal je prikazan na Sliki 6.16.

Slika 6.16: Primer izračuna funkcij p in q .



Za podan EMG signal (črna črta) sta izračunani funkciji p (rdeča črta) in q (modra črta).

Ker funkcija q opisuje lokalne spremembe amplitude, ne moremo neposredno na podlagi njene analize določiti začetka mišične aktivacije. Vemo, da imamo na 0 en dogodek mišične aktivacije, oziroma zanima nas samo prvi dogodek. Za določitev prvega dogodka lahko uporabimo preprosto metodo, ki uporabi p . Metoda nam pove časovno točko, kjer se je prvi dogodek zagotovo zgodil, kjer je torej zagotovo prišlo do mišične aktivacije. Tak dogodek opredelimo kot lokalni maksimum na p . Nato opredelimo prvi dogodek kot lokalni maksimum, katerega največja vrednost preseže vsaj polovico največje vrednosti p . Prvi dogodek izračunamo z naslednjim algoritmom:


- (1) Izračunamo največjo amplitudo p kot $p_{\max A} = \max(p) - \min(p)$, kjer je $\max(x)$ največja vrednost na x in $\min(x)$ najmanjša vrednost na x .
- (2) Poiščemo vse lokalne maksimume, ki imajo relativno višino (relativni prag) vsaj 20 % od $p_{\max A}$. Z relativnim pragom izločimo lokalne maksimume, ki so glede na okolico relativno majhni in zato ne predstavljajo dogodka.

- (3) Iz najdenih lokalnih maksimumov vzamemo prvega (časovno gledano), katerega vrh presega vsaj polovico $\max(p)$. Časovna točka izbranega lokalnega maksimuma t_S je točka, kjer je dogodek zagotovo prisoten. Ker je lokalni maksimum v točki t_S izračunan kot SD za vse elemente na oknu med t_S in $t_S + a$, popravimo točko t_S tako, da jo postavimo na sredino okna, kar zapišemo kot $t_S = t_S + a/2$.

Točka t_S je časovno gledano zagotovo za začetkom mišične aktivacije prvega dogodka. To izhaja iz dejstva, da je lokalni maksimum, na podlagi katerega smo določili t_S , večji od praga (20 % od p_{maxA}), s katerim smo opredelili dogodek mišične aktivacije.

Sedaj nam preostane še, da poiščemo začetek mišične aktivacije. Pri tem si bomo pomagali s funkcijo lokalnih sprememb amplitude q . V idealnem primeru, kjer imamo konstanten SD na neaktivnem delu EMG signala in konstanten SD na aktivnem delu EMG signal, poiščemo časovno točko, pri kateri ima funkcija q globalni maksimum ter to časovno točko proglasimo za začetek mišične aktivacije. V realnih EMG signalih se velikokrat pojavijo manjše spremembe v p (Slika 6.17), ki so posledica nihanj amplitude v neaktivnem delu EMG signala. Takšne spremembe v p lahko zelo vplivajo na iskanje začetka mišične aktivacije, saj so dejansko videti kot lokalne spremembe amplitude. Vrednost funkcije q (Slika 6.17 (B) rdeča puščica na q) je v takšnih primerih lahko primerljiva z vrednostjo q ob dejanskem začetku mišične aktivacije (Slika 6.17 (B) zelena črta na q). Drug pogost dogodek v realnih EMG signalih je, da šibkejši sledi močnejša mišična aktivacija. Lahko se zgodi, da je sprememba amplitude iz šibkejše v močnejšo mišično aktivacijo večja kot sprememba amplitude iz neaktivnega dela v šibkejšo mišično aktivacijo. V tem primeru bi algoritem, ki bi upošteval zgolj globalni maksimum funkcije q , napačno postavil začetek mišične aktivacije. Takšen primer je prikazan na Sliki 6.17, kjer je prehod iz šibkejše v močnejšo mišično aktivacijo bolj izrazit (večji q – Slika 6.17 (B) modra črta) v primerjavi s prehodom iz neaktivnega dela v šibkejšo mišično aktivacijo (manjši q – Slika 6.17 (B) zelena črta). Ob upoštevanju izključno globalnega maksimuma na q bo algoritem postavil začetek mišične aktivacije napačno, torej na prehodu iz šibkejše v močnejšo mišično aktivacijo.

Slika 6.17: Primer lokalnega nihanja amplitude in primer šibkejše začetne mišične aktivacije, kateri sledi močnejša mišična aktivacija.



(A) izvorni EMG signal. (B) p (rdeča črta) in q (črna črta), ki sta izračunani za (A). Rdeč pravokotnik označuje lokalno nihanje amplitude v EMG signalu, kar se odraži na p in q (rdeči puščici). Začetek šibke mišične aktivacije je označen z zeleno črto, medtem ko je začetek močnejše mišične aktivacije označen z modro črto.

Iskanje začetka mišične aktivacije z uporabo funkcije q začnemo tako, da najprej poiščemo lokalne ekstreme (maksimume in minimume) na q , ki se pojavijo pred t_S . Pri tem uporabimo absolutni prag P_q , ki ga določi uporabnik, in relativni prag 5 % največje vrednosti q . Z relativnim pragom izločimo lokalne ekstreme, ki so glede na okolico relativno majhni in zato ne predstavljajo pomembnega dogodka. P_q je absolutna spodnja meja za iskanje lokalnih ekstremov. Za iskanje lokalnih minimumov uporabimo recipročno vrednost q zato, da lahko uporabimo isti prag P_q tudi za ta namen. Z lokalnimi ekstremi določimo intervale, ki ne vsebujejo lokalnih sprememb amplitude. Takšni intervali se nahajajo med dvema sosednjima lokalnima ekstremoma. Sedaj lahko opredelimo začetek mišične aktivacije t_{ZA} na X kot lokalno spremembo amplitude pred t_S , ki se pojavi na prehodu iz lokalno gledano »stabilnega« intervala nižjih vrednosti (neaktivni del EMG signala) v interval višjih vrednosti (aktivni del EMG signala – pristnost mišične aktivacije). Algoritem za določitev t_{ZA} , ki je podrobno opisan v nadaljevanju, izračuna tudi oceno zanesljivosti o_{ZA} določitve t_{ZA} , ki jo uporabimo za oceno velikosti lokalne spremembe amplitude.

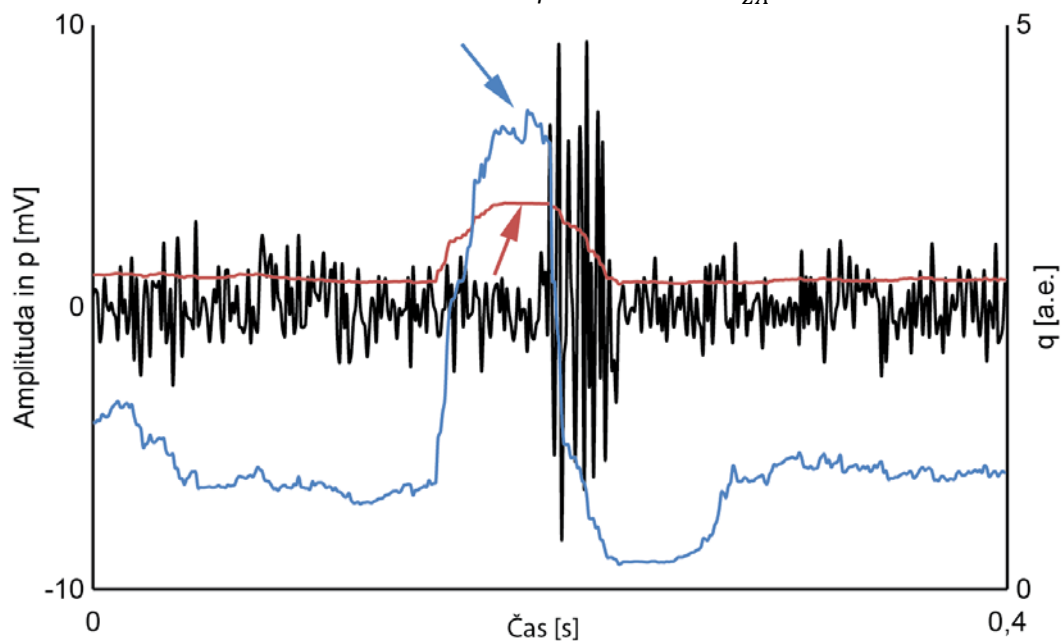
Algoritem za določitev t_{ZA} :

- Vhodni podatki so: množica lokalnih maksimumov pred t_S $LMax$, množica lokalnih minimumov pred t_S $LMin$, q , p , a , X in P_q .
 - Izhod je začetek mišične aktivacije t_{ZA} in ocena zanesljivosti o_{ZA} določitve t_{ZA} .
- (1) Če je množica $LMax$ prazna, ne moremo določiti t_{ZA} in zaključimo postopek.
 - (2) Množicama $LMin$ in $Lmax$ dodamo element z in ju uredimo po padajočem vrstnem redu. Element z dodamo zato, da upoštevamo interval od z do sosednjega ekstrema.
 - (3) Kandidata za začetek mišične aktivacije t_K nastavimo na prvi element iz $LMax$ (lokalni maksimum, ki je najbližje t_S). Kandidata za oceno zanesljivosti o_K nastavimo na $q(t_K)$. Odstranimo prvi element iz $LMax$.
 - (4) Če je v $LMax$ samo en element, zaključimo postopek in nastavimo $t_{ZA} = t_K$ ter $o_{ZA} = o_K$.
 - (5) Vzamemo prvi element t_P iz $LMax$.
 - (6) Poiščemo element t_E iz $LMax \cup LMmin$, ki je manjši od t_P , je najbližje t_P in je vsaj za a oddaljen od t_P . S tem pogojem zagotovimo, da je »stabilni« interval nižjih vrednosti širok vsaj a .
 - (7) Če so izpolnjeni vsi trije pogoji (obrazložitev pogojev je spodaj):
 - (a) $(\min(p(t_P:t_K)) / sd(X(t_E:t_P))) \geq P_q$
 - (b) $(sd(X(t_P:t_K)) / sd(X(t_E:t_P))) \geq P_q$
 - (c) $(t_K - t_P) < (t_P - t_E)$ ALI $(\min(p(t_P:t_K)) > \max(p(t_E:t_P))) \geq P_q$,
 potem nastavimo $t_K = t_P$ in $o_K = sd(X(t_P:t_K)) / sd(X(t_E:t_P))$. t_P odstranimo iz $LMax$ in skočimo na korak (4).

Pogoj (a) preprečuje, da bi bila za t_{ZA} izbrana časovna točka, ki ne pripada glavnemu dogodku, ampak je nek dogodek manjše intenzivnosti, ki se je zgodil pred glavnim dogodkom. Razlog za to je v padcu funkcije p med t_P in t_K pod prag P_q glede na interval med t_E in t_P . Pogoj (b) zagotavlja, da bo tudi razmerje SD na X med t_P in t_K ter t_E in t_P nad pragom P_q . Pogoj (c) določa, da mora biti interval med t_P in t_K krajši od intervala med t_E in t_P , ali da morajo biti vse vrednosti p na intervalu med t_P in t_K večje od vseh vrednosti p na intervalu med t_E in t_P . Poenostavljeno to pomeni, da preprečuje postavljanje t_{ZA} na začetek lokalno gledano »počasne« spremembe amplitude, ki med naraščanjem vsaj enkrat »zaniha« navzdol, kar se odrazi kot padec vrednosti p na intervalu med t_P in t_K .

Predstavljena metoda za iskanje t_{ZA} ima pomanjkljivost, da v primeru, ko amplituda naraste za čas, ki je manjši od a , narobe določi t_{ZA} . Čas, ko je amplituda povečana, označimo z b . Slika 6.18 prikazuje primer, kjer so vrednosti p približno enake na intervalu širine $a - b$ (Slika 6.18 – rdeča puščica). V tem primeru bo postavitev t_{ZA} odvisna od majhnih lokalnih sprememb amplitude neposredno pred dogodkom, ki bodo vplivale na vrednost funkcije q na intervalu širine $a - b$ (Slika 6.18 – modra puščica). Do tega pride zato, ker okno širine a zajame tudi vrednosti po dogodku, kjer amplituda že pade na nivo amplitude pred dogodkom. Funkcija q ima lahko na tem intervalu širine $a - b$ enega ali več lokalnih maksimumov, kar pomeni, da je t_{ZA} lahko kjerkoli na intervalu širine $a - b$. Glede na zapisano je pomembno, da okno a določimo tako, da bo krajše od najkrajšega pričakovanega dogodka.

Slika 6.18: Primer napačne določitve t_{ZA} .



Za podan EMG signal (črna črta) sta izračunani funkciji p (rdeča črta) in q (modra črta). Funkcija p ima plato (rdeča puščica), zaradi katerega je funkcija q na tem intervalu (modra puščica) odvisna od majhnih lokalnih sprememb amplitude EMG signala neposredno pred mišično aktivacijo.

Tukaj smo podrobno predstavili samo metodo za iskanje začetka mišične aktivacije. Za iskanje konca mišične aktivacije lahko uberemo dva pristopa. Prvi je časovno obračanje X , ki ga potem uporabimo za vhod v metodo. Druga možnost je uporaba recipročne vrednosti odločitvene funkcije q in analogna prilagoditev ostalih korakov algoritma. Recipročna vrednost funkcije q je funkcija lokalnih sprememb amplitude levega okna glede na desno okno, ko sta levo in desno

okno sosednji. S tema dvema pristopoma lahko elegantno rešimo tudi iskanje konca mišične aktivacije.

6.4.3 Vrednotenje metode za iskanje začetka mišične aktivacije

Uspešnost nove metode za iskanje začetka mišične aktivacije smo ovrednotili na množici EMG signalov, zajetih na 125 preiskovancih. Vsak preiskovanec je imel podatke za 9 mišic, dve nalogi in med 10 in 20 ponovitev naloge. Tako smo imeli skupno 85.887 primerov. Primere smo uporabili za ovrednotenje uspešnosti metode na dva načina. Najprej smo ovrednotili uspešnost zaznavanja prisotnosti mišične aktivacije v EMG signalu za tri različne vrednosti P_q (1,5, 2 in 3), nakar smo ovrednotili uspešnost iskanja začetka mišične aktivacije ter jo primerjali z drugimi metodami (integriran profil (IP), Hodges in Bui, AGLRstep in metoda z uporabo EMD) za iskanje začetka mišične aktivacije. Obe vrsti vrednotenja sta temeljili na ročnem pregledu primerov, ki so ga opravili eksperti za EMG analizo. Ročni pregled je še zmeraj edini zanesljiv način določanja začetka mišične aktivacije in velja za zlati standard na tem področju. Kljub temu se pojavi vprašanje veljavnosti ročne postavitve, saj se ekspert subjektivno odloča, kam bo postavil začetek mišične aktivacije. Vsak primer sta obravnavala dva eksperta, ki sta najprej označila, ali primer vsebuje mišično aktivacijo, in nato določila začetek te mišične aktivacije. Pri primerih, kjer so se vrednosti preveč razlikovale (za 10 ms), je takšen primer pregledal še tretji ekspert in ga ustrezno popravil, če je bilo to potrebno. Začetek mišične aktivacije se je izračunal kot povprečje dveh ocen ekspertov. Uspešnost zaznavanja prisotnosti mišične aktivacije smo ocenili z odstotkom pravilno določenih primerov (klasifikacijska točnost (KT)) ter statističnima merama občutljivosti in specifičnosti (metode so podrobno opisane v razdelku 3.1.4). Uspešnost določanja začetka mišične aktivacije smo ocenili kot povprečno odstopanje od ocene ekspertov in SD tega odstopanja. Analizo smo naredili za vsako mišico pri obeh nalogah (APP in PRO) posebej, za vse mišice za vsako nalogo posebej in za vse mišice in obe nalogi skupaj.

V Tabeli 6.4 so zbrani rezultati vrednotenja uspešnosti zaznavanja prisotnosti mišične aktivacije v EMG signalu. Najprej opazimo, da je iskanje začetka mišične aktivacije pri obeh nalogah in pri vseh mišicah najboljše za P_q pri vrednosti 2. Pri vseh analizah za $P_q = 1,5$ in $P_q = 2$ je specifičnost 100 %, kar pomeni, da so bili vsi primeri, ki niso vsebovali mišične aktivacije, pravilno določeni. Za $P_q = 3$ je specifičnost slaba (≤ 75 %) in občutljivost 100 %, kar pomeni, da so bili vsi primeri z mišično aktivacijo pravilno določeni. KT je za $P_q = 2$ pri vseh analizah večja od $P_q = 1,5$ in $P_q = 3$ razen za RA pri PRO. Za $P_q = 2$ je bila KT največja za DA in ES-L pri obeh nalogah. Nato sledijo

ES-R, MF-L, MF-R in OE-R, medtem ko je bila KT za OI, OE-L in RA slabša. Še posebej slaba je bila za RA pri PRO (KT = 74 %). Če primerjamo uspešnost med obema nalogama za vse mišice skupaj, je bila ta večja pri APP za $P_q = 1,5$ in $P_q = 2$, medtem ko je bila za $P_q = 3$ večja pri PRO. Za vse mišice in obe nalogi skupaj je bila KT zopet največja za $P_q = 2$ (91 %), kjer je bila občutljivost 90 % in specifičnost 100 %.

Tabela 6.4: Rezultati uspešnosti zaznavanja prisotnosti mišične aktivacije v EMG signalu.

| Naloga | Mišica | N | $P_q = 1,5$ | | | $P_q = 2$ | | | $P_q = 3$ | | |
|------------|--------|-------|-------------|---------|----------|-----------|---------|----------|-----------|---------|----------|
| | | | KT [%] | Obč [%] | Spec [%] | KT [%] | Obč [%] | Spec [%] | KT [%] | Obč [%] | Spec [%] |
| APP | DA | 4880 | 80 | 76 | 100 | 100 | 100 | 100 | 97 | 100 | 44 |
| | ES-L | 4880 | 80 | 76 | 100 | 100 | 100 | 100 | 82 | 100 | 15 |
| | ES-R | 4880 | 80 | 76 | 100 | 97 | 97 | 100 | 76 | 100 | 18 |
| | MF-L | 4880 | 80 | 75 | 100 | 96 | 94 | 100 | 76 | 100 | 62 |
| | MF-R | 4880 | 76 | 71 | 100 | 94 | 94 | 100 | 65 | 100 | 20 |
| | OI | 4880 | 65 | 58 | 100 | 88 | 87 | 100 | 59 | 100 | 32 |
| | OE-L | 4880 | 66 | 59 | 100 | 85 | 84 | 100 | 62 | 100 | 39 |
| | OE-R | 4880 | 75 | 70 | 100 | 92 | 91 | 100 | 66 | 100 | 30 |
| | RA | 4880 | 66 | 59 | 100 | 85 | 80 | 100 | 74 | 100 | 62 |
| PRO | DA | 4663 | 80 | 77 | 100 | 99 | 99 | 100 | 92 | 100 | 35 |
| | ES-L | 4663 | 78 | 74 | 100 | 97 | 97 | 100 | 86 | 100 | 34 |
| | ES-R | 4663 | 78 | 73 | 100 | 96 | 96 | 100 | 82 | 100 | 34 |
| | MF-L | 4663 | 75 | 70 | 100 | 95 | 92 | 100 | 83 | 100 | 71 |
| | MF-R | 4663 | 74 | 69 | 100 | 93 | 93 | 100 | 74 | 100 | 33 |
| | OI | 4663 | 68 | 61 | 100 | 83 | 77 | 100 | 76 | 100 | 64 |
| | OE-L | 4663 | 69 | 63 | 100 | 84 | 78 | 100 | 76 | 100 | 66 |
| | OE-R | 4663 | 70 | 64 | 100 | 88 | 85 | 100 | 78 | 100 | 60 |
| | RA | 4663 | 56 | 48 | 100 | 74 | 57 | 100 | 78 | 100 | 75 |
| APP | Vse | 43920 | 74 | 69 | 100 | 93 | 92 | 100 | 73 | 100 | 39 |
| PRO | Vse | 41967 | 72 | 67 | 100 | 90 | 87 | 100 | 81 | 100 | 60 |
| APP in PRO | Vse | 85887 | 73 | 68 | 100 | 91 | 90 | 100 | 77 | 100 | 50 |

N – število primerov, KT – klasifikacijska točnost, Obč – občutljivost in Spec – specifičnost.

Rezultati vrednotenja iskanja začetka mišične aktivacije v EMG signalu so prikazani v Tabeli 6.5. Če primerjamo metode po odstopanju od ročne postavitve začetka mišične aktivacije za vse mišice za obe nalogi skupaj, je najuspešnejša predlagana metoda (9 ± 8 ms), kateri sledijo po uspešnosti AGLRstep (20 ± 48 ms), Hodges in Bui (35 ± 119 ms), IP (71 ± 216 ms) in EMD (90 ± 398 ms). Popolnoma isto velja tudi za vse mišice po posamezni nalogi ločeno. Skupno gledano se metoda EMD odreže najslabše. Pri APP je nekoliko boljša v primerjavi z IP, vendar je pri PRO

izrazito slabša. Metoda Hodges in Bui je bila približno enako uspešna pri obeh nalogah (APP – 33 ms in PRO – 36 ms), vendar je bila SD izrazito slabša pri PRO (APP – 83 ms in PRO – 152 ms).

Tabela 6.5: Rezultati primerjave določanja začetka mišične aktivacije v EMG signalu med različnimi metodami.

| Naloga | Mišica | Ocena predlagane metode | Primerjava z ročno postavitvijo | | | | |
|------------|--------|-------------------------|---------------------------------|-----------|---------------|----------|------------|
| | | | Predlagana metoda | IP | Hodges in Bui | AGLRstep | EMD |
| APP | DA | 24,8 (18,9) | 3 (3) | 49 (90) | 23 (24) | 10 (16) | 19 (20) |
| | ES-L | 7,4 (7,0) | 6 (6) | 46 (135) | 28 (29) | 12 (22) | 34 (59) |
| | ES-R | 6,4 (6,4) | 7 (6) | 62 (167) | 30 (42) | 12 (24) | 42 (67) |
| | MF-L | 4,7 (4,1) | 7 (5) | 92 (188) | 33 (34) | 13 (28) | 52 (104) |
| | MF-R | 4,9 (4,6) | 6 (5) | 99 (192) | 34 (57) | 14 (30) | 52 (84) |
| | OI | 3,8 (2,5) | 13 (10) | 73 (250) | 40 (144) | 19 (45) | 93 (342) |
| | OE-L | 3,4 (1,5) | 19 (14) | 78 (263) | 35 (83) | 23 (54) | 124 (519) |
| | OE-R | 4,6 (3,7) | 10 (8) | 55 (200) | 31 (66) | 16 (41) | 78 (335) |
| | RA | 4,8 (4,0) | 22 (20) | 114 (309) | 60 (179) | 53 (88) | 179 (590) |
| PRO | DA | 14,5 (16,7) | 3 (2) | 160 (329) | 22 (62) | 13 (29) | 40 (146) |
| | ES-L | 7,8 (6,6) | 4 (3) | 25 (118) | 24 (76) | 15 (37) | 44 (160) |
| | ES-R | 6,8 (5,9) | 3 (2) | 26 (124) | 22 (23) | 16 (40) | 47 (135) |
| | MF-L | 5,3 (4,3) | 3 (4) | 23 (104) | 23 (30) | 18 (45) | 54 (147) |
| | MF-R | 5,2 (3,9) | 4 (3) | 34 (151) | 23 (42) | 19 (46) | 58 (157) |
| | OI | 4,4 (3,3) | 17 (13) | 85 (256) | 59 (218) | 37 (69) | 156 (531) |
| | OE-L | 3,9 (2,5) | 16 (12) | 121 (329) | 64 (222) | 40 (71) | 308 (932) |
| | OE-R | 5,1 (5,2) | 9 (7) | 45 (170) | 39 (182) | 28 (60) | 180 (684) |
| | RA | 3,9 (4,6) | 23 (19) | 166 (377) | 108 (409) | 42 (71) | 440 (1138) |
| APP | Vse | 7,6 (10,4) | 10 (8) | 71 (202) | 33 (83) | 18 (44) | 69 (292) |
| PRO | Vse | 6,7 (8,3) | 8 (7) | 70 (231) | 36 (152) | 23 (52) | 115 (496) |
| APP in PRO | Vse | 7,2 (9,5) | 9 (8) | 71 (216) | 35 (119) | 20 (48) | 90 (398) |

Vrednosti so zapisane kot povprečna vrednost (SD).

Metoda AGLRstep je bila boljša pri analizi APP, in sicer v povprečju za 5 ms v primerjavi s PRO. Predlagana metoda je bila nekoliko boljša pri analizi PRO, ko je v povprečju odstopala za 8 ± 7 ms od ročne postavitve začetka mišične aktivacije, medtem ko je pri APP v povprečju odstopala za 10 ± 8 ms. Vse metode (razen IP) so bile najuspešnejše pri določanju začetka mišične aktivacije za DA pri obeh nalogah. Primerljivo uspešne so bile tudi za ES-L, ES-R, MF-L in MF-R. Na drugi strani so se slabše odrezale za OI, OE-L, OE-R in najslabše za RA pri obeh nalogah. Od vseh metod je predlagana metoda edina, ki je imela SD enak ali nižji od povprečnega odstopanja od ročne postavitve začetka mišične aktivacije. Ostale metode so imele precej velik

raztros in so posledično v veliko primerih za razmeroma veliko zgrešile točen začetek mišične aktivacije. Predlagana metoda je imela najvišjo oceno zanesljivosti začetka mišične aktivacije za DA pri obeh nalogah, kar je bil odraz spremembe amplitude ob mišični aktivaciji, ki je bila za DA največja. Ocena zanesljivosti začetka mišične aktivacije predlagane metode je bila načeloma večja pri manjših odstopanjih od ročne postavitve začetka mišične aktivacije in obratno.

6.4.4 Razprava in zaključek

Po pregledu literature s področja iskanja začetka in konca mišične aktivacije smo prišli do zaključka, da nobena od predhodno uporabljenih in v literaturi poročanih metod ne ustreza zahtevam za uporabo pri avtomatski obdelavi EMG signalov. Zahteve so bile: uporaba brez posredovanja uporabnika, uporaba brez upoštevanja drugih EMG kanalov, uporaba brez znanja pridobljenega iz učne množice ter oceno zanesljivosti najdenega začetka mišične aktivacije. Na podlagi izkušenj z iskanjem začetka mišične aktivacije pri meritvah APP in PRO iz preteklih raziskav smo se odločili za razvoj nove metode, ki bo zadostila zahtevam za avtomatsko obdelavo ter se izognila pomanjkljivostim do sedaj predlaganih metod.

Glavna prednost predlagane metode pred ostalimi metodami za iskanje začetka mišične aktivacije v EMG signalu je njena lokalnost. Vse ostale metode delujejo na podlagi neke globalne lastnosti (npr. določanje osnovnega modela za metodo AGLRstep na delu EMG signala, ki je relativno daleč od obravnavanega dogodka), ki omejuje iskanje začetka mišične aktivacije. Med lokalne metode bi lahko prišteli tudi metodo, ki uporablja vzorčno entropijo, vendar je po drugi strani ta metoda pristranska zaradi pred nastavljenega okna, s katerim obdela EMG signal. Naslednja prednost predlagane metode je samostojno delovanje brez posredovanja uporabnika, kar je neizbežno pri več ostalih metodah (AGLRstep, AGLRramp in metoda z uporabo EMD). Posredovanju uporabnika se lahko izognemo tudi pri teh metodah, vendar je potem delovanje metod lahko zelo nezanesljivo (npr. »nenadzirano« postavljanje okna za določanje osnovnega modela za metodo AGLRstep privede do nezanesljivega iskanja začetka mišične aktivacije). Zadnja prednost predlagane metode je izračun ocene zanesljivosti najdenega začetka mišične aktivacije. Ta ocena nam pove, kako močna je sprememba amplitude EMG signala pri najdenem začetku mišične aktivacije in jo lahko uporabimo pri nadaljnji obdelavi EMG signala (npr. za ločevanje med zelo močnimi začetki mišične aktivacije in ostalimi). Ostale metode ne izračunajo ocene zanesljivosti najdenega začetka mišične aktivacije. Pomanjkljivost metode je izbira drsečega okna α pred njeno uporabo. Če je drseče

okno a daljše od trajanja mišične aktivacije, bo metoda napačno določila začetek mišične aktivacije. Razloge za takšno obnašanje predlagane metode smo podali pri opisu metode.

Uspešnost predlagane metode smo ovrednotili s stališča zaznave prisotnosti mišične aktivacije v EMG signalu kot tudi uspešnosti iskanja začetka mišične aktivacije v primerjavi z nekaterimi drugimi metodami. Pri analizi zaznave prisotnosti mišične aktivacije v EMG signalu smo ugotovili, da je predlagana metoda najbolj zanesljiva za $Pq = 2$. To dejansko pomeni, da mora biti lokalna sprememba SD na oknu a pred in po začetku mišične aktivacije najmanj 2. Primerjavo uspešnosti določanja začetka mišične aktivacije smo naredili glede na ročno postavitev začetka mišične aktivacije, ki so jo naredili eksperti za EMG analizo. Predlagana metoda se je izkazala za najboljšo v primerjavi z ostalimi metodami (IP, Hodges in Bui, AGLRstep in metoda z uporabo EMD). Zaključimo lahko, da je predlagana metoda primerna za avtomatsko obdelavo EMG signalov.

6.5 Izračun značilik in klasifikacija

Izračun značilik in klasifikacija sta tesno povezana. Na podlagi značilik želimo priti do zaključkov in ugotovitev o preiskovanem problemu, pri tem si pa lahko pomagamo s klasifikacijo. Z značilikami ovrednotimo preiskovan problem. Kadar je značilik veliko in ne moremo priti do željene informacije na enostaven način, si pomagamo s postopkom klasifikacije. Za ovrednotenje EMG signalov je bilo v literaturi predlagano že veliko število različnih značilik, ki se v osnovi delijo v tri skupine (Chowdhury idr., 2013): (1) značilke v časovni domeni, (2) značilke v frekvenčni domeni in (3) značilke v časovno-frekvenčni domeni. Prav tako je bila za klasifikacijo EMG problemov uporabljena široka paleta klasifikacijskih metod, ki izhajajo s področja stojnega učenja. Odločili smo se, da za to stopnjo obdelave EMG signala ne razvijamo novih metod (razen ene nove značilke), ampak uporabimo že dobro uveljavljene.

V nadaljevanju sledi opis značilik, ki smo jih uporabili za vrednotenje EMG signalov. Temu sledi opis uporabljenih klasifikacijskih metod. Na koncu sledita še predstavitev uspešnosti klasifikacije za iskanje bolnih preiskovancev in razprava.

6.5.1 Značilke

Pri ovrednotenju mišičnih aktivacij smo uporabili 21 značilik iz vseh treh predhodno opisanih skupin. Dodali smo tudi novo značilko, ki spada v skupino značilik v časovni domeni in izvira s

področja igelne EMG. Uporabljene značilke in njihovi kratki opisi so predstavljeni v nadaljevanju. Pri tem je EMG signal predstavljen z $X = [x_1, x_2, \dots, x_N]$, kjer je $N \in \mathbb{N}$ dolžina EMG signala. Za izračun nekaterih značilk je bilo potrebno X predhodno obdelati. Postopek obdelave X je podan v naslednjem razdelku.

6.5.1.1 Obdelava EMG signala za izračun značilk

Izračun nekaterih značilk ni možen na izvornem EMG signalu X in ga moramo zato predhodno obdelati. Uporabili smo standardno obdelavo EMG signala, ki je sestavljena iz treh korakov:

- (1) Filtriranje s pasovno prepustnim filtrom – Butterworth filter s prepustnim pasom med 3 in 500 Hz, stopnjo 2 in ničelnim faznim zamikom.
- (2) Glajenje s filtrom tekočih korenov povprečja kvadratov in širino okna 20 ms. Ta filter je podoben filtru tekoče aritmetične sredine, le da namesto aritmetične sredine računa koren povprečja kvadratov na tekočem oknu.
- (3) Izračun linearne ovojnice – Butterworth nizko prepustni filter s prepustnim pasom pod 10 Hz, stopnjo 2 in ničelnim faznim zamikom.

Tako obdelan X označimo z $Y = [y_1, y_2, \dots, y_N]$, kjer je $N \in \mathbb{N}$ dolžina EMG signala.

6.5.1.2 Značilke v časovni domeni

Latenca (L) je časovna razlika med mehanskim začetkom izvajanja naloge in začetkom mišične aktivacije in jo imenujemo tudi elektro-mehanska zakasnitev. Pri PRO je bila latenca določena kot razlika med trenutkom sprostitve bremena in začetkom mišične aktivacije. Pri APP je bila latenca določena kot razlika med začetkom hotenega giba in začetkom mišične aktivacije. Za začetek hotenega giba smo vzeli začetek mišične aktivacije na DA.

SD latence (L_{SD}) je SD L.

Povprečna zaporedna razlika latence (PZRL) (Selvan, 2011) je povprečje razlik latenc med dvema zaporednima ponovitvama iste naloge. To značilko lahko izračunamo le, če imamo več ponovitev iste naloge. Če je $L = [l_1, l_2, \dots, l_N]$ množica latenc zaporednih ponovitev naloge in je N število ponovitev naloge, potem je

$$PZRL = \frac{1}{N-1} \sum_{k=1}^{N-1} (l_{k+1} - l_k).$$

Integriran EMG (IEMG) je vsota absolutnih vrednosti EMG signala, ki jo izračunamo kot

$$IEMG = \sum_{k=1}^N |y_k|.$$

Povprečna absolutna vrednost (PAV) je povprečna vrednost vsote absolutnih vrednosti EMG signala, ki jo izračunamo kot

$$PAV = \frac{1}{N} \sum_{k=1}^N |y_k|.$$

Modificirana povprečna absolutna vrednost (MPAV) je izvedenka PAV, ki uporablja utežitveno funkcijo u . Izračunamo jo kot

$$MPAV = \frac{1}{N} \sum_{k=1}^N u_k |y_k|$$

$$u = \begin{cases} 1, & \text{če } 0,25 * N \leq k \leq 0,75 * N \\ 4 * k/N, & \text{če } 0,25 * N > k \\ 4 * (k - N)/N, & \text{če } 0,75 * N < k \end{cases}.$$

Enostaven kvadrat integrala (EKI) je vsota kvadratov vrednosti EMG signala in ga izračunamo kot

$$EKI = \sum_{k=1}^N y_k^2.$$

Varianca (VAR) je povprečna vsota kvadratov vrednosti EMG signala, ki jo izračunamo kot

$$VAR = \frac{1}{N-1} \sum_{k=1}^N y_k^2.$$

Koren povprečja kvadratov (KPK) je koren povprečne vsote kvadratov vrednosti EMG signala, ki ga izračunamo kot

$$KPK = \sqrt{\frac{1}{N} \sum_{k=1}^N y_k^2}.$$

Hitrost prirasta amplitude (HPA) je sprememba amplitude v času, ki jo izračunamo kot

$$HPA = \frac{x_b - x_a}{b - a},$$

kjer sta a in b dve časovni točki na X .

Dolžina signala (DS) je skupna dolžina EMG signala skozi čas, ki jo izračunamo kot

$$DS = \sum_{k=1}^{N-1} |x_{k+1} - x_k|.$$

Amplituda Willison (WA) je število, kolikokrat amplituda dveh zaporednih vrednosti EMG signala preseže prag, ki ga določi uporabnik. Pri tej nalogi smo prag določili kot 10 % največje amplitude EMG signala. WA izračunamo kot

$$WA = \sum_{k=1}^{N-1} f(|x_k - x_{k+1}|);$$

$$f(x) = \begin{cases} 1, & \text{če } x \geq 0,1 * \max(X) \\ 0, & \text{sicer} \end{cases}.$$

Vzorčna entropija (VE) je mera kompleksnosti, ki ne upošteva samo-podobnih vzorcev (Costa, Goldberger, & Peng, 2005). Parametra $m = 2$ in $r = 0,2 * sd(X)$ sta bila nastavljena, kot so to predlagali Zhao in sodelavci (2006).

6.5.1.3 Značilke v frekvenčni domeni

Povprečna frekvenca (PFre) je povprečna frekvenca, ki je izračunana iz močnostnega spektra z enačbo

$$PFre = \frac{\sum_{k=1}^M f_k P_k}{\sum_{k=1}^M P_j},$$

kjer je f_k frekvenca k -tega elementa močnostnega spektra, P_k vrednost k -tega elementa močnostnega spektra in M število elementov močnostnega spektra.

Mediana frekvenca (MFre) je frekvenca, pri kateri je močnostni spekter razdeljen na dva dela z enako močjo. Izračunamo jo iz močnostnega spektra z enačbo

$$\sum_{k=1}^{MFre} P_k = \sum_{k=MFre}^M P_k = \frac{1}{2} \sum_{k=1}^M P_k,$$

kjer je P_k vrednost k -tega elementa močnostnega spektra in M število elementov močnostnega spektra.

Modificirana povprečna frekvenca (MPFre) je povprečna frekvenca, ki je izračunana iz amplitudnega spektra z enačbo

$$PFre = \frac{\sum_{k=1}^M f_k A_k}{\sum_{k=1}^M A_k},$$

kjer je f_k frekvenca k -tega elementa amplitudnega spektra, A_k vrednost k -tega elementa amplitudnega spektra in M število elementov amplitudnega spektra.

Modificirana mediana frekvenca (MMFre) je frekvenca, pri kateri je amplitudni spekter razdeljen na dva dela z enako amplitudo. Izračunamo jo iz amplitudnega spektra z enačbo

$$\sum_{k=1}^{MFre} A_k = \sum_{k=MFre}^M A_k = \frac{1}{2} \sum_{k=1}^M A_k,$$

kjer je A_k vrednost k -tega elementa amplitudnega spektra in M število elementov amplitudnega spektra.

6.5.1.4 Značilke v časovno-frekvenčni domeni

Povprečno absolutno vrednost koeficientov diskretne valčne transformacije izračunamo iz koeficientov (podrobnih in približnih koeficientov), pridobljenih z DVT. Pri izračunu DTV smo uporabili Daubechies (db07) izvorni valček in štiri nivoje dekompozicije (Phinyomark idr., 2009). Za vseh pet dobljenih koeficientov (štiri podrobne in enega približnega) smo izračunali povprečne absolutne vrednosti (DVT-MAV-1, DVT-MAV-2, DVT-MAV-3 DVT-MAV-4 DVT-MAV-5).

6.5.2 Klasifikacijske metode

S klasifikacijskimi metodami smo želeli poiskati množico značilik, na podlagi katere bi lahko ugotavljali, ali je preiskovanec bolan (ima BSH) ali zdrav. Dodatno smo želeli poiskati množico značilik za vsako mišico posebej, na podlagi katere bi lahko klasificirali mišico kot takšno s pričakovanim (zdravim) ali nepričakovanim (tveganim) vzorcem aktivacije. Klasifikacijski problemi so bili v domeni EMG pogosto preiskovani že v preteklosti. Takšna primera sta

klasifikacija gibov dlani (Phinyomark, Limsakul, & Phukpattaranont, 2011) in klasifikacija obraznih mimik (Hamedi idr., 2013). V tej študiji smo uporabili že uveljavljeni metodi za klasifikacijo (SVM in UNM), ki sta hkrati primerni tudi za avtomatsko obdelavo. Za obe klasifikacijski metodi je bila poročana zadovoljiva uspešnost reševanja klasifikacijskih problemov v domeni EMG (Chowdhury idr., 2013; Khokhar, Xiao, & Menon, 2010; Oskoei, 2008). SVM metoda, ki deluje dobro na velikem številu vhodnih značilk, je uporabljala Gaussovo jedro s stopnjo dva, tri ali štiri ter mehko mejo enako dva, tri ali štiri. UNM je imela med dva in šest skritih nevronov in je uporabljala povratno zanko za adaptacijo uteži in praga pri učenju modela. Za morebitno izboljšanje uspešnosti klasifikacijskih metod smo uporabili dva pristopa za zmanjševanje dimenzij, linearna diskriminantna analiza (*angl. linear discriminant analysis* (LDA)) in analiza osnovnih komponent (*angl. principal component analysis* (PCA)).

6.5.3 Uspešnost klasifikacije za iskanje bolnih preiskovancev

Uspešnost klasifikacije za iskanje bolnih preiskovancev smo ovrednotili na množici EMG signalov, pridobljenih na 125 preiskovancih, od katerih je 28 preiskovancev imelo simptome BSH. Vsak preiskovanec je imel podatke za 8 mišic (DA smo izpustili, ker ne vpliva na stabilizacijo trupa), dve nalogi in med 10 in 20 ponovitev naloge. Tako smo imeli skupno 76.344 primerov (od tega je bilo 17.216 primerov od preiskovancev s simptomi BSH). V prvem koraku smo izračunali značilke za začetni del mišične aktivacije za vsako ponovitev. Značilke so bile izračunane samo za začetni del mišične aktivacije, ker so na tem delu prisotne informacije, ki so posledica izvajanih nalog (APP in PRO). Uporabili smo dva intervala za izračun značilke: 25 ms po začetku mišične aktivacije in 50 ms po začetku mišične aktivacije. Vsaka značilka je bila izračunana za obe nalogi, vsako mišico in vsako ponovitev posebej. Vse značilke, razen L , L_{SD} in PZRL, so bile izračunane na obeh intervalih. L , L_{SD} in PZRL, ki so odvisne od elektro-mehanske zakasnitve, so bile izračunane na podlagi razlike med mehanskim začetkom izvajanja naloge in začetkom mišične aktivacije (glej razdelek 6.5.1.2). Izračunane značilke smo pred uporabo za klasifikacijo ustrezno pripravili. Za obe nalogi, vsako mišico in oba intervala posebej, smo izračunali povprečne vrednosti in SD za vse ponovitve naloge za vsako značilko posebej. Pred tem smo odstranili vrednosti, ki so odstopale več kot dva SD od povprečja množice. Tako dobljene vrednosti smo uporabili za klasifikacijsko analizo. Za klasifikacijo smo uporabili SVM in UNM z nastavitvami, ki smo jih opisali v razdelku 6.5.2. SVM in UNM smo uporabili samostojno kot tudi v kombinaciji z LDA in PCA. Uspešnost klasifikacijskih metod smo preverjali s

klasifikacijsko točnostjo (KT) in 10-kratnim sorazmernim prečnim preverjanjem ter statističnima merama občutljivosti in specifičnosti, ki smo jo podrobno opisali v razdelku 3.1.4. Primeri so bili razdeljeni v 10 podmnožic, tako da je bila zastopanost razredov (preiskovanci s simptomi BSH in ostali) približno enaka. Razdelitev primerov v podmnožice je bila narejena glede na preiskovance (vsi primeri enega preiskovanca so bili zmeraj znotraj iste podmnožice). Rezultate klasifikacije smo primerjali z referenčnim klasifikatorjem, ki vse primere dodeli razredu z največjo zastopanostjo. Množico značilk, s katero bi lahko ugotavljali, ali je preiskovanec bolan (ima BSH) ali zdrav, smo iskali s klasifikacijo na vseh možnih podmnožicah vseh značilk. To smo naredili zato, ker so nekatere značilke med seboj odvisne, kar lahko pomembno vpliva na uspešnost klasifikatorjev. Množico značilk za vsako mišico posebej, ki bi klasificirala mišico kot takšno s pričakovanim (zdravim) ali nepričakovanim (tveganim) vzorcem aktivacije, smo prav tako iskali s klasifikacijo na vseh možnih podmnožicah značilk ene mišice.

Rezultati klasifikacijske analize za iskanje bolnih preiskovancev (z BSH) so bili za vse analize slabi. V primerjavi z referenčnim klasifikatorjem, katerega KT je bila 78 %, občutljivost 0 % in specifičnost 100 %, nismo dobili zadovoljive KT v nobenem primeru. Še najboljše se je odrezala UNM (pet skritih nevronov) v kombinaciji z LDA na vseh značilkah iz obeh nalog (APP in PRO) skupaj in pri tem dosegla 83 % KT, 71 % občutljivost in 87 % specifičnost. Torej je najboljši klasifikator dosegel 5 % izboljšanje KT glede na referenčni klasifikator. Klasifikatorji, s katerimi smo iskali mišice s pričakovanim (zdravim) ali nepričakovanim (tveganim) vzorcem aktivacije, so dosegli KT med 61 % in 81 %. Najboljše se je odrezala UNM (pet skritih nevronov) v kombinaciji z LDA za MF-R pri APP na vseh značilkah in pri tem dosegla 81 % KT, 60 % občutljivost in 87 % specifičnost. Ker so bili rezultati klasifikacije analize slabi, se nismo ukvarjali z nadaljnjo podrobno optimizacijo klasifikatorjev, saj smo ocenili, da to ni smiselno.

6.5.4 Razprava in zaključek

S predstavljenimi značilkami in klasifikacijskimi metodami smo želeli rešiti problem iskanja množice značilk, na podlagi katere bi lahko ugotavljali, ali je preiskovanec bolan (ima BSH) ali zdrav. Poiskati smo želeli tudi množico značilk za vsako mišico posebej, ki bi klasificirala mišico kot mišico s pričakovanim (zdravim) ali nepričakovanim (tveganim) vzorcem aktivacije. Za reševanje zadanega problema smo uporabili veliko množico podatkov, ki je vsebovala tako zdrave preiskovance kot tudi preiskovance s simptomi BSH.

Rezultati klasifikacijske analize so pokazali, da ne moremo določiti množice značilik, na podlagi katere bil lahko napovedovali BSH ali identificirali mišice s tveganim odzivom aktivacije. Razlogov za to je lahko več: od slabo izbranih značilik ali klasifikacijskih metod do nezmožnosti reševanja problema z informacijo iz EMG. Prav slednje se nam zdi bolj verjetno, saj je bila analiza narejena na širokem spektru značilik in uporabi uveljavljenih klasifikacijski metod, za katere je bila poročana zadovoljiva uspešnost reševanja klasifikacijskih problemov v domeni EMG (Chowdhury idr., 2013; Khokhar idr., 2010; Oskoei, 2008). Predvidevamo, da bi večjo uspešnost klasifikacije dosegli z uporabo dodatnih testov za ovrednotenje živčno-mišične funkcije ledveno-medeničnega predela trupa. Takšni testi so: test največje moči upogibalk in iztegovalk trupa, test utrudljivosti upogibalk in iztegovalk trupa, test kinestetično senzorične funkcije trupa ter test splošnega telesnega ravnotežja.

Uporabljene značilke in klasifikacijske metode so vsekakor primerne za avtomatsko obdelavo EMG signalov, saj delujejo samostojno s pred nastavljenimi parametri. Klasifikacijske metode lahko naučimo na neki referenčni množici podatkov ali uporabimo podatke iz trenutno preiskovanega problema in preverimo, če je klasifikacija za preiskovani problem zadovoljivo uspešna.

7 Aplikacija za avtomatsko obdelavo EMG signalov

Aplikacija za avtomatsko obdelavo EMG signalov človeškega trupa je bila razvita na podlagi predhodno opisanih pristopov za avtomatsko obdelavo EMG signalov. Aplikacijo smo razvili v razvojnem okolju Labview, v katerem smo združili vse stopnje obdelave EMG signala in jih primerno vizualizirali. Aplikacija omogoča avtomatsko obdelavo EMG signalov trupa z vsemi vključenimi stopnjami obdelave (predobdelava EMG signalov, odstranjevanje EKG motnje iz EMG signala, iskanje začetka in konca mišične aktivacije ter izračun značilk in klasifikacija). Uporabnik lahko izbira med ročno obdelavo ali popolnoma avtomatsko obdelavo podatkov. Pri ročni obdelavi podatkov lahko uporabnik izbira metode in nastavlja njihove vhodne parametre za vse stopnje obdelave EMG signala. Pri iskanju začetka in konca mišične aktivacije lahko tudi ročno popravlja avtomatsko postavljen začetek in konec mišične aktivacije. Aplikacija omogoča obdelavo velikih količin podatkov, katerih končne in tudi vmesne rezultate shrani v primerni obliki za nadaljnjo uporabo. V nadaljevanju sledi še podrobnejši opis posamezne stopnje obdelave EMG signala v aplikaciji.


Podatki, pridobljeni z meritvami EMG signalov človeškega trupa, so razporejeni po preiskovancu in nalogi (APP in PRO). Najprej se podatki očistijo po postopku, ki je opisan v razdelku 6.1. Nato se vsaka meritev shrani v obliko, ki omogoča hiter dostop do ustreznega dela meritve in enostavno nadaljnjo obdelavo. Tako se meritve razporedijo po preiskovancu, nalogi, mišici in ponovitvi naloge. Zajeti EMG signal, ki vsebuje vse ponovitve naloge, je potrebno razrezati na ustrezne intervale, ki vsebujejo eno ponovitev naloge. Intervale se določili na podlagi začetka naloge, kar pri meritvah APP predstavlja zvočni signal in pri meritvah PRO sprostitvev bremena. Za vsako ponovitev se vzame interval med 5 s pred in 5 s po začetku naloge, da dobimo 10 s dolg interval za vsako ponovitev naloge. Vsi nadaljnji koraki obdelave se nato izvedejo na tako dobljenih ponovitvah naloge.

V prvi stopnji obdelave se vsako ponovitev filtrira z Butterworth pasovno prepustnim filtrom s frekvenčnim pasom med 3 in 500 Hz, stopnjo 2 in ničelnim faznim zamikom. Uporabnik lahko izbere tudi odstranjevanje šuma z DVT.

V drugi stopnji obdelave se iz vsake ponovitve odstrani EKG artefakte (če jih vsebuje) z novo metodo, ki smo jo predstavili v razdelku 6.3.2. Privzete predloge za iskanje EKG artefaktov so prikazane na Sliki 6.11. Vse tri predloge se prezrcalijo preko časovne osi in tako dobimo skupno 6 predlog za iskanje EKG artefaktov. Uporabnik lahko uporabi tudi druge predloge za iskanje EKG artefaktov.

V tretji stopnji obdelave se za vsako ponovitev poišče začetek mišične aktivacije z novo metodo, ki smo jo predstavili v razdelku 6.4.2. Privzeti vhodni parametri algoritma so: $P_{SD} = 0,01$, $a = 50$ ms, $P_q = 2$. Uporabnik lahko uporabi tudi druge metode za iskanje začetka mišične aktivacije (IP, Hodges in Bui, AGLRstep (Slika 7.1) in metoda z uporabo EMD) in spreminja njene parametre.

Slika 7.1: Primer zaslona za preverjanje in postavljanje začetka mišične aktivacije.



Prikazani so štiri EMG signali (bele črte) z mišično aktivacijo in postavitev začetka mišične aktivacije (rumeni markerji) z metodo AGLRstep. Uporabnik lahko s premikom rumenih markerjev popravi morebitne napačne postavitve. Navpične zelene črte prikazujejo interval, na katerem se pričakuje začetek mišične aktivacije, in služijo zgolj za pomoč uporabniku.

V četrti stopnji obdelave se izračunajo značilke za začetni del mišične aktivacije za vsako ponovitev. Značilke se izračunajo samo za začetni del mišične aktivacije, ker so na tem delu prisotne informacije odvisne od izvajanih nalog (APP in PRO). Uporabita se dva intervala za izračun značilk: 25 ms po začetku mišične aktivacije in 50 ms po začetku mišične aktivacije. Vsaka značilka se izračunana za obe nalogi, vsako mišico in vsako ponovitev posebej. Vse

značilke, razen L , L_{SD} in $PZRL$, se izračunajo na obeh intervalih. L , L_{SD} in $PZRL$, ki so odvisne od elektro-mehanske zakasnitve, se izračunajo na podlagi razlike med mehanskim začetkom izvajanja naloge in začetkom mišične aktivacije (glej razdelek 6.5.1.2).

V peti stopnji obdelave se uporabijo klasifikacijske metode za napovedovanje BSH in tveganega vzorca aktivacije za posamezno mišico. Za obe nalogi (APP in PRO), vsako mišico in oba intervala posebej se izračunajo povprečne vrednosti in SD za vse ponovitve naloge za vsako značilko posebej. Pred tem se odstranijo še vrednosti, ki odstopajo več kot dva SD od povprečja množice. Tako dobljene vrednosti se uporabijo za klasifikacijo. Za klasifikacijo sta na voljo pristopa SVM in UNM ter možnost uporabe LDA ali PCA za zmanjševanje dimenzij. Uporabnik izbere poljubno kombinacijo metod pred začetkom analize. Napovedovanje BSH in tveganega vzorca aktivacije za posamezno mišico se naredi z že naučenimi klasifikatorji na celotni množici podatkov, ki smo jo pridobili v okviru te raziskave. Uporabnik lahko izbere tudi svojo učno množico, ki jo uporabi za učenje izbrane klasifikacijske metode.

8 Zaključek

Doktorska disertacija obravnava problem avtomatske obdelave EMG signalov človeškega trupa pri meritvah APP in PRO. Problem avtomatske obdelave je prisoten v vseh stopnjah obdelave EMG signala (predobdelava EMG signala, odstranjevanje EKG motnje iz EMG signala, iskanje začetka in konca mišične aktivacije ter izračun značilik in klasifikacija). Z rešitvijo tega problema smo odpravili zamudno in monotono ročno delo, ki je bilo neizbežno pri obdelavi EMG signalov. Problema predstavljene doktorske disertacije smo se lotili s podrobnim pregledom obstoječe literature, analizo obstoječih metod ter zasnovno, implementacijo in vrednotenjem uspešnosti dveh novo razvitih metod za obdelavo EMG signalov. Novi metodi smo ovrednotili na veliki množici raznolikih EMG signalov človeškega trupa pri meritvah APP in PRO.

Pri snovanju novih metod smo se osredotočili na njihovo uporabnost za avtomatsko obdelavo EMG signalov ter hkrati čim večjo zanesljivost. S takšnim pristopom nam je uspelo narediti aplikacijo za avtomatsko obdelavo EMG signalov, ki deluje brez posredovanja uporabnika razen pri začetnih nastavitvah metod in izbiri podatkov. Obe novo razviti metodi sta morali zadostiti naslednjim zahtevam:

- Uporaba brez posredovanja uporabnika, ki omogoča objektivno obdelavo EMG signala brez možnosti napak, ki so posledica subjektivne presoje uporabnika.
- Uporaba brez upoštevanja drugih EMG kanalov, kar omogoča obdelavo vsakega EMG signala neodvisno od EMG signalov drugih mišic.
- Uporaba brez znanja, pridobljenega iz predhodne učne množice, kar omogoča uporabo brez predhodnega znanja o preiskovanem problemu (razen v stopnji klasifikacije, kjer je to neizbežno).
- Ocena zanesljivosti rezultata, na podlagi katere lahko sprejmemo odločitev o poteku nadaljnje obdelave EMG signala.
- Uporaba brez dodatno zajetega EKG signala v primeru odstranjevanja EKG motnje, ki omogoča obdelavo podatkov brez nepotrebne dodatnega dela pri izvajanju meritev in obdelavo že obstoječih podatkov, ki nimajo zajetega EKG signala.

Za potrebe prve stopnje obdelave EMG signala smo najprej naredili pregled obstoječih metod za odstranjevanje motenj iz EMG signala. Na podlagi pregleda literature in izvedenih testov

smo se odločili, da za to stopnjo obdelave ne razvijamo novih pristopov, ampak uporabimo obstoječe metode, ki so primerne za avtomatsko obdelavo EMG signalov. Uporabili smo dve metodi: Butterworth pasovno prepustni filter in odstranjevanje šuma z DVT. Pri postopku avtomatske obdelave smo uporabljali izključno Butterworth pasovno prepustni filter, saj odstranjevanje šuma z DVT odstrani precejšen del EMG signala.

Za potrebe druge stopnje obdelave EMG signala smo razvili novo metodo za odstranjevanje EKG motnje iz EMG signala. Za razvoj nove metode smo se odločili na podlagi analize obstoječih metod, ki ali niso bile primerne za avtomatsko obdelavo EMG signalov ali pa niso bile dovolj uspešne pri odstranjevanju EKG motnje iz EMG signala. Nova metoda temelji na dobro uveljavljeni metodi DTW za obdelavo digitalnih signalov. DTW smo uporabili za iskanje EKG artefaktov z različnimi predlogami EKG artefaktov. Na množici najdenih kandidatov za EKG artefakte smo nato naredili še dodatno analizo, ki preveri, kateri kandidati so pravi EKG artefakti ter poišče manjkajoče EKG artefakte. Tako zasnovana metoda je primerna za avtomatsko obdelavo EMG signalov. Uspešnost predlagane metode smo preverili na umetno ustvarjenih EMG signalih z dodano EKG motnjo in na realnih EMG signalih. V obeh primerih se je predlagana metoda izkazala za zanesljivo, tako pri zaznavi prisotnosti EKG motnje v EMG signalu kot tudi pri uspešnosti odstranjevanja EKG motnje iz EMG signala.

Za potrebe tretje stopnje obdelave EMG signala smo razvili novo metodo za iskanje začetka in konca mišične aktivacije v EMG signalu. Pri pregledu literature in preliminarnih testiranjih obstoječih metod za iskanje začetka mišične aktivacije smo ugotovili, da obstoječe metode zahtevajo posredovanje uporabnika in/ali zaradi svoje narave ne iščejo lokalnega začetka mišične aktivacije. Seveda takšne metode niso primerne za avtomatsko obdelavo EMG signala. Nova metoda za iskanje začetka mišične aktivacije predpostavlja, da imamo opravka z eno mišično aktivacijo in zato ni primerna za iskanje začetka mišične aktivacije na EMG signalu, kjer imamo več zaporednih mišičnih aktivacij. Uspešnost predlagane metode smo ovrednotili s stališča zaznave prisotnosti mišične aktivacije v EMG signalu kot tudi uspešnosti iskanja začetka mišične aktivacije v primerjavi z nekaterimi drugimi metodami. Primerjavo uspešnosti iskanja začetka mišične aktivacije smo naredili glede na ročno postavitve začetka mišične aktivacije, ki so jo naredili eksperti za EMG analizo. V obeh primerih je bila uspešnost metode zadovoljiva, hkrati pa je bila tudi najboljša metoda za iskanje začetka mišične aktivacije v primerjavi z drugimi testiranimi metodami.

Za potrebe četrte in pete stopnje obdelave EMG signala smo uporabili že poznane pristope za napovedovanje BSH in identifikacije mišic s tveganim vzorcem aktivacije. Za obstoječe pristope

so bile v literaturi poročane številne uspešne uporabe za reševanje različnih primerov s področja EMG. V nabor značilk smo dodali eno novo značilko (PZRL), ki izvira iz obdelave igelnega EMG. Ocenili smo, da obstoječe značilke in klasifikacijske metode zadostujejo za analizo našega problema, saj nismo našli nobenega tehtnega razloga v prid razvoju novih klasifikacijskih metod, specifičnih za EMG obdelavo. Rezultati klasifikacijske analize so bili slabi, kar pomeni, da sta bili napovedovanje BSH in identifikacija mišic s tveganim vzorcem aktivacije nezanesljivi. Sklepamo, da EMG signali človeškega trupa, pridobljeni pri izvajanju obeh nalog (APP in PRO), vsebujejo premalo informacije za reševanje zastavljenega problema. V prid temu sklepu je tudi analiza na širokem spektru značilk in uporabljenih klasifikacijskih metod, za katere je bila poročana zadovoljiva uspešnost reševanja klasifikacijskih problemov v domeni EMG. Hkrati predvidevamo, da bi večjo uspešnost klasifikacije dosegli z uporabo dodatnih testov za ovrednotenje živčno-mišične funkcije ledveno-medeničnega predela trupa.

Na koncu smo vse stopnje obdelave EMG signalov združili v aplikacijo za avtomatsko obdelavo EMG signalov človeškega trupa pri meritvah APP in PRO. Poleg avtomatske obdelave lahko uporabnik izbire tudi ročno obdelavo podatkov. Pri ročni obdelavi podatkov je možno izbirati metode in nastavljeni njihove vhodne parametre za vse stopnje obdelave. Pri iskanju začetka in konca mišične aktivacije lahko tudi ročno popravljamo avtomatsko postavljen začetek in konec mišične aktivacije. Prednosti aplikacije za avtomatsko obdelavo EMG signalov človeškega trupa pri meritvah APP in PRO so:

- odprava ročnega obdelovanja EMG signalov,
- hitra obdelava velikih količin EMG signalov,
- velik prihranek časa,
- objektivna obdelava EMG signalov,
- možnost postopne ročne obdelave EMG signalov,
- vizualizacija poteka obdelave EMG signalov v vseh stopnjah,
- shranjevanje rezultatov obdelav po stopnjah v primerni obliki za nadaljnjo uporabo.

Hipoteze, ki smo jih postavili na začetku študije, so bile:

- H1: Nove metode za odstranjevanje motenj iz EMG signalov bodo bolj zanesljive kot trenutno znane metode.
- H2: Nove metode za iskanje začetka in konca mišične aktivacije bodo delovale popolnoma avtomatsko (brez posredovanja uporabnika).

- H3: Izbrane značilke in klasifikacijska metoda bodo zanesljivo ločile mišice s pričakovanim/zdravim in nepričakovanim/tveganim vzorcem aktivacije.
- H4: Vse razvite metode, povezane v celoto, bodo delovale popolnoma avtomatsko (brez posredovanja uporabnika).

Sedaj, ko smo naredili celotno raziskavo in analizirali vse metode, lahko zaključimo, da smo potrdili hipoteze H1, H2 in H4, medtem ko smo zavrgli hipotezo H3.

Disertacija vsebuje naslednje pomembnejše prispevke k znanosti:

- Razvoj sistema in metodologije za obdelavo velikih količin podatkov, pridobljenih z meritvami EMG signalov človeškega trupa pri meritvah APP in PRO.
- Razvoj sistema in metodologije za avtomatsko obdelavo EMG signalov po stopnjah (predobdelava EMG signalov, odstranjevanje EKG motenj, iskanje začetka in konca mišične aktivacije, izračun značilk in klasifikacija).
- Razvoj dveh novih metod za obdelavo EMG signala (za odstranjevanje EKG motnje in iskanje začetka in konca mišične aktivacije).
- Aplikacija razvite metodologije v konkretni domeni, t.j. EMG človeškega trupa in ovrednotenje na veliki količini realnih podatkov.

Ker se z reševanjem določenih problemov, ki so se pojavili v tej nalogi, nismo ukvarjali, nam lahko služijo kot izhodišča za nadaljnje raziskave na področju obdelave EMG signalov. Metode za avtomatsko obdelavo EMG signalov smo preizkusili samo na EMG signalih človeškega trupa, zato bi bilo smiselno narediti skrbno analizo tudi na drugih skupinah mišic ob izvajanju različnih nalog. Metoda za odstranjevanje EKG motnje iz EMG signala temelji na predpostavki, da začetni del EMG signala ne vsebuje mišične aktivacije. Z nadgradnjo metode, ki bi se izognila tej predpostavki, bi dobili metodo za odstranjevanje EKG motnje na kateremkoli EMG signalu. Pri iskanju začetka mišične aktivacije v EMG signalu smo se osredotočili na iskanje začetka enega dogodka mišične aktivacije. Če ne moremo določiti okna, na katerem je zgolj ena mišična aktivacija, je potrebno EMG signal razdeliti na segmente, ki vsebujejo natanko eno mišično aktivacijo. Za ta namen bi bilo smiselno razviti metodo za avtomatsko segmentacijo EMG signala.

9 Literatura

- Abbink, J. H., van der Bilt, A., & van der Glas, H. W. (1998). Detection of onset and termination of muscle activity in surface electromyograms. *Journal of Oral Rehabilitation*, 25(5), 365–9.
- Akansu, A. N., & Haddad, R. A. (1992). *Multiresolution Signal Decomposition: Transforms, Subbands, and Wavelets*. Orlando: Academic Press.
- Allison, G. T. (2003). Trunk muscle onset detection technique for EMG signals with ECG artefact. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 13(3), 209–16.
- Andrade, A. O., Nasuto, S., Kyberd, P., Sweeney-Reed, C. M., & Van Kaniijn, F. R. (2006). EMG signal filtering based on Empirical Mode Decomposition. *Biomedical Signal Processing and Control*, 1(1), 44–55.
- Barandun, M., von Tscherner, V., Meuli-Simmen, C., Bowen, V., & Valderrabano, V. (2009). Frequency and conduction velocity analysis of the abductor pollicis brevis muscle during early fatigue. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 19(1), 65–74.
- Barr, K. P., Griggs, M., & Cadby, T. (2005). Lumbar stabilization: core concepts and current literature, Part 1. *American Journal of Physical Medicine & Rehabilitation / Association of Academic Physiatrists*, 84(6), 473–80.
- Bartolo, A., Roberts, C., Dzwonczyk, R. R., & Goldman, E. (1996). Analysis of diaphragm EMG signals: comparison of gating vs. subtraction for removal of ECG contamination. *Journal of Applied Physiology (Bethesda, Md. : 1985)*, 80(6), 1898–902.
- Bergmark, A. (1989). Stability of the lumbar spine. A study in mechanical engineering. *Acta Orthopaedica Scandinavica. Supplementum*, 230, 1–54.
- Bonato, P., D'Alessio, T., & Knaflitz, M. (1998). A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait. *IEEE Transactions on Bio-Medical Engineering*, 45(3), 287–99.
- Bouisset, S., & Do, M.-C. (2008). Posture, dynamic stability, and voluntary movement. *Neurophysiologie Clinique = Clinical Neurophysiology*, 38(6), 345–62.
- Cesqui, B., Tropea, P., Micera, S., & Krebs, H. (2013). EMG-based pattern recognition approach in post stroke robot-aided rehabilitation: a feasibility study. *Journal of NeuroEngineering and Rehabilitation*, 10(1), 75.

- Cholewicki, J., Greene, H. S., Polzhofer, G. K., Galloway, M. T., Shah, R. A., & Radebold, A. (2002). Neuromuscular function in athletes following recovery from a recent acute low back injury. *The Journal of Orthopaedic and Sports Physical Therapy*, *32*(11), 568–75.
- Cholewicki, J., Silfies, S. P., Shah, R. A., Greene, H. S., Reeves, N. P., Alvi, K., & Goldberg, B. (2005). Delayed trunk muscle reflex responses increase the risk of low back injuries. *Spine*, *30*(23), 2614–20.
- Chowdhury, R. H., Reaz, M. B. I., Ali, M. A. B. M., Bakar, A. A. A., Chellappan, K., & Chang, T. G. (2013). Surface electromyography signal processing and classification techniques. *Sensors (Basel, Switzerland)*, *13*(9), 12431–66.
- Christov, I. I., & Daskalov, I. K. (1999). Filtering of electromyogram artifacts from the electrocardiogram. *Medical Engineering & Physics*, *21*(10), 731–6.
- Comon, P. (1994). Independent component analysis, A new concept? *Signal Processing*, *36*(3), 287–314.
- Cordo, P. J., & Nashner, L. M. (1982). Properties of postural adjustments associated with rapid arm movements. *Journal of Neurophysiology*, *47*(2), 287–302.
- Costa, M., Goldberger, A., & Peng, C.-K. (2005). Multiscale entropy analysis of biological signals. *Physical Review E*, *71*(2).
- De Luca, C. J. (1985). *Muscles Alive: Their Functions Revealed by Electromyography*. Easton: Williams & Wilkins.
- De Luca, C. J. (1997). The Use of Surface Electromyography in Biomechanics. *Journal of Applied Biomechanics*, *13*(2), 135–163.
- De Luca, C. J., Gilmore, L. D., Kuznetsov, M., & Roy, S. H. (2010). Filtering the surface EMG signal: Movement artifact and baseline noise contamination. *Journal of Biomechanics*, *43*(8), 1573–9.
- De Wolf, S., Slijper, H., & Latash, M. L. (1998). Anticipatory postural adjustments during self-paced and reaction-time movements. *Experimental Brain Research*, *121*(1), 7–19.
- Drake, J. D. M., & Callaghan, J. P. (2006). Elimination of electrocardiogram contamination from electromyogram signals: An evaluation of currently used removal techniques. *Journal of Electromyography and Kinesiology*, *16*(2), 175–187.
- Drobnič-Kovač, D. (2002). Obravnava bolnika z bolečino v križu. *Zdravniški vestnik*, *71*, 97–100.
- Frymoyer, J. W., Pope, M. H., Clements, J. H., Wilder, D. G., MacPherson, B., & Ashikaga, T. (1983). Risk factors in low-back pain. An epidemiological survey. *The Journal of Bone and Joint Surgery. American Volume*, *65*(2), 213–218.
- Gilles, J. (2013). Empirical Wavelet Transform. *IEEE Transactions on Signal Processing*, *61*(16), 3999–4010.

- Granata, K. P., Slota, G. P., & Bennett, B. C. (2004). Paraspinal muscle reflex dynamics. *Journal of Biomechanics*, 37(2), 241–7.
- Hamed, M., Salleh, S.-H., Astaraki, M., & Noor, A. M. (2013). EMG-based facial gesture recognition through versatile elliptic basis function neural network. *Biomedical Engineering Online*, 12(1), 73.
- Hammill, R. R., Beazell, J. R., & Hart, J. M. (2008). Neuromuscular consequences of low back pain and core dysfunction. *Clinics in Sports Medicine*, 27(3), 449–62, ix.
- Hermens, H. J., Freriks, B., Disselhorst-Klug, C., & Rau, G. (2000). Development of recommendations for SEMG sensors and sensor placement procedures. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 10(5), 361–74.
- Hibbs, A. E., Thompson, K. G., French, D. N., Hodgson, D., & Spears, I. R. (2011). Peak and average rectified EMG measures: which method of data reduction should be used for assessing core training exercises? *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 21(1), 102–11.
- Hodges, P., van den Hoorn, W., Dawson, A., & Cholewicki, J. (2009). Changes in the mechanical properties of the trunk in low back pain may be associated with recurrence. *Journal of Biomechanics*, 42(1), 61–6.
- Hodges, P. W. (2001). Changes in motor planning of feedforward postural responses of the trunk muscles in low back pain. *Experimental Brain Research*, 141(2), 261–6.
- Hodges, P. W., & Bui, B. H. (1996). A comparison of computer-based methods for the determination of onset of muscle contraction using electromyography. *Electroencephalography and Clinical Neurophysiology*, 101(6), 511–9.
- Hodges, P. W., Moseley, G. L., Gabrielsson, A., & Gandevia, S. C. (2003). Experimental muscle pain changes feedforward postural responses of the trunk muscles. *Exp Brain Res*, 151(2), 262–71.
- Hodges, P. W., & Richardson, C. A. (1997). Feedforward contraction of transversus abdominis is not influenced by the direction of arm movement. *Experimental Brain Research*, 114(2), 362–70.
- Hodges, P. W., & Richardson, C. A. (1998). Delayed postural contraction of transversus abdominis in low back pain associated with movement of the lower limb. *Journal of Spinal Disorders*, 11(1), 46–56.
- Hof, A. L. (2009). A simple method to remove ECG artifacts from trunk muscle EMG signals. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 19(6), e554–5.
- Hu, Y., Mak, J. N. F., & Luk, K. D. K. (2009). Effect of electrocardiographic contamination on surface electromyography assessment of back muscles. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 19(1), 145–56.

- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903–995.
- Hussain, M. S., Reaz, M. B. I., Mohd-Yasin, F., & Ibrahimy, M. I. (2009). Electromyography signal analysis using wavelet transform and higher order statistics to determine muscle contraction. *Expert Systems*, 26(1), 35–48.
- Jacobs, J. V, Henry, S. M., & Nagle, K. J. (2009). People with chronic low back pain exhibit decreased variability in the timing of their anticipatory postural adjustments. *Behavioral Neuroscience*, 123(2), 455–8.
- Kandel, E., Schwartz, J., & Jessell, T. (2000). *Principles of Neural Science*. New York: McGraw-Hill.
- Kanekar, N., Santos, M. J., & Aruin, A. S. (2008). Anticipatory postural control following fatigue of postural and focal muscles. *Clinical Neurophysiology: Official Journal of the International Federation of Clinical Neurophysiology*, 119(10), 2304–13.
- Khokhar, Z. O., Xiao, Z. G., & Menon, C. (2010). Surface EMG pattern recognition for real-time control of a wrist exoskeleton. *Biomedical Engineering Online*, 9(1), 41.
- Lambeek, L. C., Bosmans, J. E., Van Royen, B. J., Van Tulder, M. W., Van Mechelen, W., & Anema, J. R. (2010). Effect of integrated care for sick listed patients with chronic low back pain: economic evaluation alongside a randomised controlled trial. *BMJ (Clinical Research Ed.)*, 341, c6414.
- Latash, M. L. (2008). *Neurophysiological Basis of Movement*. Human Kinetics.
- Lee, J., Ko, H., Lee, S., Lee, H., & Yoon, Y. (2009). Detection technique of muscle activation intervals for sEMG signals based on the empirical mode decomposition. *Conference Proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2009*, 336–9.
- Lee, K. J., & Lee, B. (2013). Removing ECG artifacts from the EMG: A comparison between combining empirical-mode decomposition and independent component analysis and other filtering methods. In *2013 13th International Conference on Control, Automation and Systems (ICCAS 2013)* (pp. 181–184). IEEE.
- Leinonen, V., Kankaanpaa, M., Luukkonen, M., Kansanen, M., Hanninen, O., Airaksinen, O., & Taimela, S. (2003). Lumbar paraspinal muscle function, perception of lumbar position, and postural control in disc herniation-related back pain. *Spine (Phila Pa 1976)*, 28(8), 842–8.
- Lidierth, M. (1986). A computer based method for automated measurement of the periods of muscular activity from an EMG and its application to locomotor EMGs. *Electroencephalography and Clinical Neurophysiology*, 64(4), 378–80.

- Lin, C.-H. (2008). Frequency-domain features for ECG beat discrimination using grey relational analysis-based classifier. *Computers & Mathematics with Applications*, 55(4), 680–690.
- Lu, G., Brittain, J.-S., Holland, P., Yianni, J., Green, A. L., Stein, J. F., ... Wang, S. (2009). Removing ECG noise from surface EMG signals using adaptive filtering. *Neuroscience Letters*, 462(1), 14–9.
- Mak, J. N. F., Hu, Y., & Luk, K. D. K. (2010). An automated ECG-artifact removal method for trunk muscle surface EMG recordings. *Medical Engineering & Physics*, 32(8), 840–8.
- Masani, K., Sin, V. W., Vette, A. H., Thrasher, T. A., Kawashima, N., Morris, A., ... Popovic, M. R. (2009). Postural reactions of the trunk muscles to multi-directional perturbations in sitting. *Clinical Biomechanics (Bristol, Avon)*, 24(2), 176–82.
- McGill, S. M. (2001). Low back stability: from formal description to issues for performance and rehabilitation. *Exercise and Sport Sciences Reviews*, 29(1), 26–31.
- Merletti, R., & Parker, P. (2004). *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press.
- Mijović, B., De Vos, M., Gligorijević, I., Taelman, J., & Van Huffel, S. (2010). Source separation from single-channel recordings by combining empirical-mode decomposition and independent component analysis. *IEEE Transactions on Bio-Medical Engineering*, 57(9), 2188–96.
- Müller, M. (2007). Dynamic Time Warping. In *Information Retrieval for Music and Motion* (pp. 69–84). Berlin, Heidelberg: Springer.
- O'Sullivan, P. B. (2000). Lumbar segmental “instability”: clinical presentation and specific stabilizing exercise management. *Manual Therapy*, 5(1), 2–12.
- Oskoei, M. A. (2008). Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. *IEEE Transactions on Biomedical Engineering*, 55(8), 1956–1965.
- Panjabi, M. M. (1992). The stabilizing system of the spine. Part I. Function, dysfunction, adaptation, and enhancement. *Journal of Spinal Disorders*, 5(4), 383–9; discussion 397.
- Panjabi, M. M. (2006). A hypothesis of chronic back pain: ligament subfailure injuries lead to muscle control dysfunction. *European Spine Journal*, 15(5), 668–676.
- Pedersen, M. T., Essendrop, M., Skotte, J. H., Jørgensen, K., & Fallentin, N. (2004). Training can modify back muscle response to sudden trunk loading. *European Spine Journal: Official Publication of the European Spine Society, the European Spinal Deformity Society, and the European Section of the Cervical Spine Research Society*, 13(6), 548–52.
- Perry, J., & Burnfield, J. (2010). *Gait Analysis: Normal and Pathological Function*. Thorofare: Slack Incorporated.

- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009a). A Comparative Study of Wavelet Denoising for Multifunction Myoelectric Control. In *2009 International Conference on Computer and Automation Engineering* (pp. 21–25). IEEE.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009). A Novel Feature Extraction for Robust EMG Pattern Recognition. *Journal of Computing*, *1*(1), 71–80.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2009b). An optimal wavelet function based on wavelet denoising for multifunction myoelectric control. In *2009 6th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology* (Vol. 02, pp. 1098–1101). IEEE.
- Phinyomark, A., Limsakul, C., & Phukpattaranont, P. (2011). Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification. *Measurement Science Review*, *11*(2), 45–52.
- Phinyomark, A., Quaine, F., Charbonnier, S., Serviere, C., Tarpin-Bernard, F., & Laurillau, Y. (2013). EMG feature evaluation for improving myoelectric pattern recognition robustness. *Expert Systems with Applications*, *40*(12), 4832–4840.
- Rabiner, L. R., & Juang, B.-H. (1993). *Fundamentals of Speech Recognition*. PTR Prentice Hall.
- Radebold, A., Cholewicki, J., Panjabi, M. M., & Patel, T. C. (2000). Muscle response pattern to sudden trunk loading in healthy individuals and in patients with chronic low back pain. *Spine*, *25*(8), 947–54.
- Radebold, A., Cholewicki, J., Polzhofer, G. K., & Greene, H. S. (2001). Impaired postural control of the lumbar spine is associated with delayed muscle response times in patients with chronic idiopathic low back pain. *Spine*, *26*(7), 724–30.
- Rafiee, J., Rafiee, M. A., Yavari, F., & Schoen, M. P. (2011). Feature extraction of forearm EMG signals for prosthetics. *Expert Systems with Applications*, *38*(4), 4058–4067.
- Reeves, N. P., Narendra, K. S., & Cholewicki, J. (2007). Spine stability: the six blind men and the elephant. *Clinical Biomechanics (Bristol, Avon)*, *22*(3), 266–74.
- Santello, M., & McDonagh, M. J. (1998). The control of timing and amplitude of EMG activity in landing movements in humans. *Experimental Physiology*, *83*(6), 857–74.
- Santos, B. R., Larivière, C., Delisle, A., McFadden, D., Plamondon, A., & Imbeau, D. (2011). Sudden loading perturbation to determine the reflex response of different back muscles: a reliability study. *Muscle & Nerve*, *43*(3), 348–59.
- Selvan, V. A. (2011). Single-fiber EMG: A review. *Annals of Indian Academy of Neurology*, *14*(1), 64–7.
- Stauder, G., Flachenecker, C., Daumer, M., & Wolf, W. (2001). Onset Detection in Surface Electromyographic Signals: A Systematic Comparison of Methods. *EURASIP Journal on Advances in Signal Processing*, *2001*(2), 67–81.

- Staude, G. H. (2001). Precise onset detection of human motor responses using a whitening filter and the log-likelihood-ratio test. *IEEE Transactions on Bio-Medical Engineering*, 48(11), 1292–305.
- Staude, G., & Wolf, W. (1999). Objective motor response onset detection in surface myoelectric signals. *Medical Engineering & Physics*, 21(6-7), 449–67.
- Stokes, I. A. F., Fox, J. R., & Henry, S. M. (2006). Trunk muscular activation patterns and responses to transient force perturbation in persons with self-reported low back pain. *European Spine Journal*, 15(5), 658–667.
- Stokes, I. A., Gardner-Morse, M., Henry, S. M., & Badger, G. J. (2000). Decrease in trunk muscular response to perturbation with preactivation of lumbar spinal musculature. *Spine*, 25(15), 1957–64.
- Strang, A. J., & Berg, W. P. (2007). Fatigue-induced adaptive changes of anticipatory postural adjustments. *Experimental Brain Research*, 178(1), 49–61.
- Taelman, J., Mijovic, B., & Huffel, S. Van. (2011). ECG Artifact Removal from Surface EMG Signals by Combining Empirical Mode Decomposition and Independent Component Analysis. *BIOSIGNALS*.
- Torres, M. E., Colominas, M. A., Schlotthauer, G., & Flandrin, P. (2011). A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 4144–4147). IEEE.
- Von Tscharner, V. (2000). Intensity analysis in time-frequency space of surface myoelectric signals by wavelets of specified resolution. *Journal of Electromyography and Kinesiology*, 10(6), 433–445.
- Von Tscharner, V., Eskofier, B., & Federolf, P. (2011). Removal of the electrocardiogram signal from surface EMG recordings using non-linearly scaled wavelets. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 21(4), 683–8.
- Willigenburg, N. W., Daffertshofer, A., Kingma, I., & van Dieën, J. H. (2012). Removing ECG contamination from EMG recordings: a comparison of ICA-based and other filtering procedures. *Journal of Electromyography and Kinesiology: Official Journal of the International Society of Electrophysiological Kinesiology*, 22(3), 485–93.
- Willson, J. D., Dougherty, C. P., Ireland, M. L., & Davis, I. M. (2005). Core stability and its relationship to lower extremity function and injury. *The Journal of the American Academy of Orthopaedic Surgeons*, 13(5), 316–25.
- Winter, D. A. (2009). *Biomechanics and Motor Control of Human Movement*. Wiley.
- Wu, Z., & Huang, N. E. (2009). Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method. *Advances in Adaptive Data Analysis*, 01(01), 1–41.
- Xu, Q., Quan, Y., Yang, L., & He, J. (2013). An adaptive algorithm for the determination of the onset and offset of muscle contraction by EMG signal processing. *IEEE Transactions on*

Neural Systems and Rehabilitation Engineering : A Publication of the IEEE Engineering in Medicine and Biology Society, 21(1), 65–73.

- Zazulak, B., Cholewicki, J., & Reeves, N. P. (2008). Neuromuscular control of trunk stability: clinical implications for sports injury prevention. *The Journal of the American Academy of Orthopaedic Surgeons*, 16(9), 497–505.
- Zazulak, B. T., Hewett, T. E., Reeves, N. P., Goldberg, B., & Cholewicki, J. (2007). Deficits in neuromuscular control of the trunk predict knee injury risk: a prospective biomechanical-epidemiologic study. *The American Journal of Sports Medicine*, 35(7), 1123–30.
- Zhan, C., Yeung, L. F., & Yang, Z. (2010). A wavelet-based adaptive filter for removing ECG interference in EMGdi signals. *Journal of Electromyography and Kinesiology : Official Journal of the International Society of Electrophysiological Kinesiology*, 20(3), 542–9.
- Zhang, X., & Zhou, P. (2013). Filtering of surface EMG using ensemble empirical mode decomposition. *Medical Engineering & Physics*, 35(4), 537–42.
- Zhao, J., Cai, H., Liu, H., & Hirzinger, G. (2006). A Novel EMG Motion Pattern Classifier Based on Wavelet Transform and Nonlinearity Analysis Method. In *2006 IEEE International Conference on Robotics and Biomimetics* (pp. 1494–1499). IEEE.
- Zhou, P., Lowery, M. M., Weir, R. F., & Kuiken, T. A. (2005). Removal of ECG Artifacts from Myoelectric Prosthesis Control Signals. Myoelectric Symposium.
- Zhou, P., & Zhang, X. (2014). A novel technique for muscle onset detection using surface EMG signals without removal of ECG artifacts. *Physiological Measurement*, 35(1), 45–54.
- Zivanovic, M., & González-Izal, M. (2012). Nonstationary harmonic modeling for ECG removal in surface EMG signals. *IEEE Transactions on Bio-Medical Engineering*, 59(6), 1633–40.