ELEKTRIČNA AKTIVNOST PARALUMBALNE MUSKULATURE U TRODIMENZIJSKOM FAZNOM PROSTORU TIJEKOM IZLAGANJA CIJELOG TIJELA VIBRACIJAMA

Dinjar, Kristijan

Doctoral thesis / Disertacija

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Medicine / Sveučilište Josipa Jurja Strossmayera u Osijeku, Medicinski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:152:059469

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository of the Faculty of Medicine Osijek

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

MEDICINSKI FAKULTET OSIJEK

Kristijan Dinjar

ELEKTRIČNA AKTIVNOST PARALUMBALNE MUSKULATURE U TRODIMENZIJSKOM FAZNOM PROSTORU TIJEKOM IZLAGANJA CIJELOG TIJELA VIBRACIJAMA

Doktorski rad

Osijek, 2017.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

MEDICINSKI FAKULTET OSIJEK

Kristijan Dinjar

ELEKTRIČNA AKTIVNOST PARALUMBALNE MUSKULATURE U TRODIMENZIJSKOM FAZNOM PROSTORU TIJEKOM IZLAGANJA CIJELOG TIJELA VIBRACIJAMA

Doktorski rad

Osijek, 2017.

Mentor rada: prof. dr. sc. Sven Kurbel, dr. med.

Komentorica rada: prof. dr. sc. Svjetlana Marić

Rad ima: 83 lista

SADRŽAJ

1. UVOD 1

1.1. O VIBRACIJAMA KROZ POVIJEST DO DANAS 1

1.2. VIBRACIJA CIJELOGA TIJELA 3

1.3. SKELETNO MIŠIĆNO VLAKNO 5

1.4. UMOR MIŠIĆA 12

1.5. KONCEPT FRAKTALA 15

2. HIPOTEZA 18

3. CILJ ISTRAŽIVANJA 19

4. ISPITANICI I METODE 20

4.1. ISPITANICI 20

4.2. METODE 21

4.2.1. DOSTUPNE METODE PROCJENE AKTIVNOSTI PARALUMBALNE MUSKULATURE POD OPTEREĆENJEM 21

4.2.2. SNIMANJE TRODIMENZIONALNOGA ELEKTROKARDIOGRAFSKOG ZAPISA VISOKE REZOLUCIJE 22

4.2.3. BILJEŽENJE I POHRANA PODATAKA SNIMANJA 23

4.2.4. PRIPREMA PODATAKA ZA STATISTIČKU OBRADU IZRAČUNOM FRAKTALNE DIMENZIJE 26

4.2.5. DEFINIRANJE NAČINA MJERENJA ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE 27

4.3. STATISTIČKA OBRADA PODATAKA 28

5. REZULTATI 31

5.1. REZULTATI PILOT STUDIJE VIZUALIZACIJE PROMJENE ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA 31

5.2. REZULTATI ANALIZE FRAKTALNOSTI ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA 33

5.2.1. RAZLIKE U FRAKTALNOJ DIMENZIJI OVISNO O SPOLU I UTRENIRANOSTI PARALUBALNE MUSKULATURE 34

5.2.2. RAZLIKE U FRAKTALNOJ DIMENZIJI IZMEĐU ISPITANIKA SVRSTANIH U EM KLASTERE PO TIPU UMARANJA 41

5.2.3. FRAKTALNE DIMENZIJE RAČUNATE *WAVELET* TRANSFORMACIJOM IZMEĐU EM KLASTERA ISPITANIKA....50

6. RASPRAVA....53

6.1. ZNAČAJKE VIZUALIZACIJE PROMJENE ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA 53

6.2. ZNAČAJKE FRAKTALNOSTI ELEKTRIČNE AKTIVNOSTI PARALUMBLANE MUSKULATURE TIJEKOM NAPORA....54

6.3. ZNAČAJKE RAZLIKA FRAKTALNE DIMENZIJE IZMEĐU ISPITANIKA SVRSTANIH U EM KLASTERE PO TIPU UMARANJA....56

6.3.1. RAZLIKE FRAKTALNE DIMENZIJE RAČUNATE *WAVELET* TRANSFORMACIJOM IZMEĐU EM KLASTERA ISPITANIKA 58

7. ZAKLJUČCI 60

8. SAŽETAK....63

9. SUMMARY 65

10. LITERATURA 67

11. ŽIVOTOPIS....75

POPIS TABLICA

Tablica 4.1. Podjela ispitanika prema stupnju utreniranosti s obzirom na dob 20

Tablica 5.1. Prikaz ovisnosti R/S fraktalne dimenzije prikupljenih podataka o spolu i utreniranosti ... 34

Tablica 5.2. Prikaz razdioba vrijednosti fraktalne dimenzije *wavelet* transformacijom 40

Tablica 5.3. Razlike R/S fraktalne dimenzije između EM klastera ispitanika 42

Tablica 5.4. Razlike fraktalne dimenzije računate *wavelet* transformacijom između EM klastera ispitanika 50

POPIS SLIKA

Slika 4.1. Položaj ispitanika na vibrirajućoj podlozi za vrijeme snimanja.....23

Slika 4.2. Prikaz generirajućih oblika slojeva u ispitanika koji na vibrirajućoj podlozi stoji uspravno.25

Slika 4.3. Prikaz generirajućih oblika slojeva u ispitanika koji na vibrirajućoj podlozi stoji nagnut naprijed.....25

Slika 4.4. Prikaz programa Benoit za izračun fraktalne dimenzije 27

Slika 5.1. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 27 godina.....31

Slika 5.2. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 25 godina.....32

Slika 5.3. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 22 godine.....32

Slika 5.4. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 21 godinu.....33

Slika 5.5. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika R/S fraktalne dimenzije po osi X ovisna o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – prva četvrtina izlaganja, T2 – druga četvrtina izlaganja, X – os faznog prostora, D1 – R/S izračun fraktalne dimenzije). 35

Slika 5.6. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika R/S fraktalne dimenzije po osi Y ovisno o stupnju utreniranosti (trening 2 – 6 – utreniranost 2. – 6. stupnja, T1 – prva četvrtina izlaganja, T2 – druga četvrtina izlaganja, D1 – R/S izračun fraktalne dimenzije, Y – os faznog prostora). 36

Slika 5.7. Pravokutni grafikon (raspon 25 □ 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika u R/S fraktalnoj dimenziji ovisnoj o spolu u smjeru osi Z (naprijed □ nazad) tijekom četiri faze izlaganja vibracijama (spol 1 □ muški spol, spol 2 – ženski spol, T1 – T4 – prva do četvrta četvrtina izlaganja, Z □ os faznog prostora, D1 □ R/S izračun fraktalne dimenzije). 37

Slika 5.8. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike u fraktalnoj dimenziji temporalnoga vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – T4 – prva do čevrta četvrtina izlaganja, VEK – temporalni vektor, D1 – R/S izračun fraktalne dimenzije). 38

Slika 5.9. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike vrijednosti R/S fraktalne dimenzije centrifugalnog vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 i T2 – prva i druga četvrtina izlaganja, VEK2 – centrifugalni vektor, D1 – R/S izračun fraktalne dimenzije).....39

Slika 5.10. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike vrijednosti *wavelet* fraktalne dimenzije temporalnog vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – T4 – prva do čevrta četvrtina izlaganja, VEK – temporalni vektor, D2 – *wavelet* izračun fraktalne dimenzije). 41

Slika 5.11. Prikaz razdiobe stupnja utreniranosti ispitanika u tri klastera ispitanika po mijeni R/S fraktalne dimenzije gibanja po osi Y (trening – stupanj utreniranosti od 2 do 6)....43

Slika 5.12. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe dobi ispitanika u tri klastera ispitanika po mijeni R/S fraktalne dimenzije gibanja po osi Y. 44

Slika 5.13. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz tipa promjene R/S fraktalne dimenzije gibanja po osi Y tijekom četiri faze izlaganja vibracijama (T1 – T4 – prva do četvrta četvrtina izlaganja, Y – os faznog prostora, D1 – R/S izračun fraktalne dimenzije). 45

Slika 5.14. Prikaz razdiobe po spolu u tri klastera ispitanika po mijeni R/S fraktalne dimenzije temporalnog vektora (1 – muški spol, 2 – ženski spol)....46

Slika 5.15. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u tri klastera ispitanika po mijeni fraktalne dimenzije temporalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK – temporalni vektor, D1 – R/S izračun fraktalne dimenzije). 47

Slika 5.16. Prikaz razdiobe po spolu u dva klastera ispitanika po mijeni R/S fraktalne dimenzije centrifugalnog vektora (1 – muški spol, 2 – ženski spol)....48

Slika 5.17. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u dva klastera ispitanika po mijeni fraktalne dimenzije centrifugalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK2 – centrifugalni vektor, D1 – R/S izračun fraktalne dimenzije)....49

Slika 5.18. Prikaz razdiobe po spolu u tri klastera ispitanika po mijeni *wavelet* fraktalne dimenzije temporalnog vektora (1 – muški spol, 2 – ženski spol)....51

Slika 5.19. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe *wavelet* fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u tri klastera ispitanika po mijeni fraktalne dimenzije temporalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK – temporalni vektor, D2 – *wavelet* izračun fraktalne dimenzije)....52

1. UVOD

1.1. O VIBRACIJAMA KROZ POVIJEST DO DANAS

Iako su još u doba Antičke Grčke obrađenu i umotanu ranu trakom vezali za mehanizam koji ju je lagano tresao, vjerujući da se tako poboljšava i pospješuje cijeljenje rane, povijest istraživanja učinaka vibracija na ljudsko tijelo ostaje kratka, a spoznaje još uvijek nedovoljne. Zabilježeno je u 16. st. u Japanu da se perkusijskom vibracijom relaksira mišić te se tako brže rješava rigiditeta i spazama. Jedna od metoda liječenja bolova u leđima i napada bubrežnih kamenaca bila je u Engleskoj u 17. st. vožnja u zaprežnim kolima koja brzo vibriraju jer se voze po što neravnijoj podlozi. Osoba koja je prva počela pozitivno gledati i primjenjivati vibracije čak u terapijske svrhe bio je Jean-Martin Charcot, više poznat kao otac suvremene neurologije. On se u periodu od 1880. do 1890. koristio vibracijama u terapiji Parkinsonove bolesti. Prvi je dizajnirao vibrirajuću stolicu te je svoj rad objavio 1892. godine u časopisu *Scientific American*. Od tada se i drugi autori počinju koristiti vibracijama u terapijske svrhe, kao što su Georg Taylor iz Amerike i Gustav Zander iz Švedske. Američki liječnik John Kellogg, mnogo poznatiji po patentiranju *cornflakesa* 1878. godine, dao je napraviti vibrirajuće uređaje – vibrirajuću stolicu, vibrirajuću platformu i vibrator za ruke – liječeći njima konstipaciju, glavobolje i bolove u donjem dijelu leđa. Međutim, Kellogg nikada nije napravio nijedno istraživanje koji bi objavio. Prvi pokus s objavljenim rezultatima u kojima se upotrebljava vibrirajući krevet objavili su Whedon i suradnici 1949. godine zaključivši da vibrirajući krevet kod zdravih pojedinaca sprječava gubitak koštane mase za 50 % (1, 2). U drugoj polovici 20. stoljeća u Istočnoj Njemačkoj doktor William Bierman 1960. godine istražuje cikličke vibracije i njihov utjecaj na fleksiju trupa te rad objavljuje iste godine u časopisu *American Journal of Physical Medicine* (3). Zemlje istočnoga bloka najviše upotrebljavaju rad s različitim izvorima vibracija. Upotrebljavane su u sklopu ruskog svemirskog programa, vojne obuke, a zatim i u sportu, najviše u periodu od 1960 do 1980. godine bez objava rezultata i informacija koje bi bile dostupne ostalim autorima. Ruski sportski znanstvenik Nazarov koristio se biomehaničkom stimulacijom vibracijama (4, 5). On je vibracije u periodu do 1985. godine testirao na balerinama, ali je također radio i pokuse s vibrirajućim krevetom i dokazao da je gubitak koštane mase manji za 34 % za razliku od Whedona i sur. Važno je napomenuti da se ruski znanstvenici nisu koristili vibrirajućim podlogama kakve danas poznajemo već uređajima za biomehaničku stimulaciju izravno na

mišićima ili tetivama. Kako bi se prevenirala mišićna atrofija i gubitak koštane mase pri dužem boravku u svemiru, Europska svemirska agencija testirala je različite vrste sustava za vibraciju kao dodatni trening. Naime, zbog nedostatka gravitacije, astronauti relativno brzo razvijaju mišićnu atrofiju i gubitak koštane mase (6). Prvi test za vibracijsku terapiju astronauta zapravo je učinjen na životinjskom modelu i već nakon toga, bez ranijega testiranja na ljudima, mnogi proizvođači i trgovci rabe taj isti pokus kao opravdanje da samo nakon njega odmah počnu prodavati uređaje za vibracije ljudima. Do kraja devedesetih godina primjena vibracija kod astronauta rabljena je uglavnom u terapijske svrhe kada su atrofija i osteoporoza već nastupile. Međutim, u posljednjih 20 godina, vibracijski trening, kao preventivna metoda, uspješno rabe Bedrest Studies of the European Space Agency (ESA) i Njemačka svemirska agencija (DLR). Ovoga puta koristile su se alternativne vibracije u smislu treninga koje bi smanjile i prevenirale negativni utjecaj bestežinskog stanja i potaknule mikrogravitaciju te tako prevenirale atrofije mišića i gubitak koštane mase (7, 8, 9, 10). Njemačka svemirska agencija uspješno je testirala uređaj za vibracijski trening u sklopu *Galileo Space* projekta u nekoliko letačkih kampanja i prikazala da se primjena vibracija može izvoditi i kada je gravitacija jednaka nuli (11). Vibracija se u literaturi naziva različitim terminima; od biomehaničke stimulacije, biomehaničke oscilacije, vibracijskog treninga, vibracijske terapije do danas najčešće rabljenoga termina – vibracije cijeloga tijela (WBV – *whole body vibration*). Komercijalnu inačicu uređaja za vibracije cijeloga tijela kakvu danas poznajemo dizajnirao je nizozemski atletski trener Guus van der Meer 1999. godine i nazvao ju *Power Plate*. Vođeni prvim rezultatima istraživanja utjecaja vibracija na ljudsko tijelo kao što je porast snage, jačine, ravnoteže i fleksibilnosti mišića, vibracijski treninzi postajali su sve popularniji, do te mjere da su neke tvornice proizvodile i prodavale uređaje za vibraciju cijeloga tijela sa zanemarivim znanstvenim pristupom i testiranjem samoga uređaja. Prva istraživanja i autori pokazali su da nakon naglog izlaganja cijeloga tijela vibracijama mišićna sila i snaga biva u porastu te da se učinkovitošću vibracijski trening može mjeriti s konvencionalnim vježbama snage mišića. Dva autora, M. Cardinale i C. Bosco, u periodu od 1999. do 2003. godine najzaslužniji su za rane znanstvene rezultate utjecaja vibracija cijeloga tijela na mišiće (12 - 16).

1.2. VIBRACIJA CIJELOGA TIJELA

Vibracija se u literaturi spominje pod različitim nazivima; od biomehaničke stimulacije, biomehaničke oscilacije, vibracijskog treninga, vibracijske terapije do danas najčešće rabljenoga termina – vibracije cijeloga tijela (WBV – *whole body vibration*). Vibracija cijeloga tijela (WBV) je širok pojam koji opisuje trenutak kada se bilo koja vibracija bilo koje frekvencije prenese na ljudsko tijelo. Treba imati na umu da se ni kroz takvu općenitu definiciju WBV kao pojam ne bi smio miješati s vibracijama kojima smo izloženi svakodnevno u životu, bilo da smo neizravno ili izravno vezani za nekakav posao pri kojemu se upotrebljavaju strojevi ili uređaji koji vibracije svojim radom prenose na radnika. Iako u literaturi dominira pojam vibracijski trening, koji označuje vježbanje pri kojemu se vibracije različitih amplituda/frekvencija/snage prenose na zasebne dijelove tijela pomoću preciziranih položaja ekstremiteta, odnosno njihovih zglobova u definiranom vremenu, o WBV-u se danas može govoriti dijeleći ga u dvije kategorije:

- WBV fizioterapija – uključuje istezanje i masaže kada je tijelo u laganom dodiru s vibracijskim uređajem, a nalazi se u stanju nula napora. Uglavnom osoba stoji uspravno na vibracijskoj podlozi u opuštenom stavu skupljenih nogu.

- WBV trening – suprotan terapiji, trening koji se do sada provodi u najmanje pet različitih položaja tijela. Svi položaji tijela su statički i ne zadržava ih se više od 1 minute da ne bi došlo do oštećenja zglobova. Uvjet da bi trening uspio je da se položaj tijela održava ispravno te se umor mišića postigne u roku 1 minute. Razlog tako brzog postizanja mišićnog umora je ekscentrična kontrakcija koja se ponavlja do 40 puta u sekundi, za razliku od koncentrične kontrakcije koja je snažnija, ali sporija. U konačnici označava upotrebu vibracija kao mehaničke stimulacije za vježbanje mišićno-koštanih struktura tijela i time poboljšanje mišićne snage, sile i fleksibilnosti.

Vibracijski trening mogli bismo odrediti i kao mehaničku stimulaciju koja prenosi sinusoidalne oscilacije na tijelo dok se istodobno obavljaju statičke i/ili dinamičke vježbe (35). Na takav način vibracije cijeloga tijela kod ciljanoga mišića ili mišićne skupine izazivaju ekscentričnu izometrijsku kontrakciju i anaerobnu aktivnost mišića koja je suprotna klasičnom kardiotreningu. Ako vibrirajuća platforma na sebi ima dovoljnu masu i amplituda je ispod 50 Hz odgovor mišića bit će čista ekscentrična kontrakcija (17). U prvim istraživanjima i radovima, kao i u najnovijima, WBV se uglavnom spominje i koristiti kao

WBV trening – vježba, a manje kao terapija. Prava je istina da se u većini radova misli na terapijski učinak bio on rabljen kao preventiva ili pak za poboljšanje bolesnoga stanja. Tako se danas vibracije cijeloga tijela sve više zagovaraju kao jedna od terapijskih metoda u liječenju osteoporoze, sarkopenije i metaboličkih sindroma (18), rehabilitaciji (19), fizikalnoj terapiji (20), ali i profesionalnom sportu, očuvanju ljepote te kao dio wellness sadržaja. Kronična izloženost WBV-u uzrokuje štetne učinke na zdravlje kao što su umor, bol u donjem dijelu leđa, problemi s vidom, iritacija i ometanje normalnog rada pluća, trbuha ili mokraćnog mjehura i nuspojave na probavni, urogenitalni te ženski reproduktivni sustav. Kao primjer najbolje će poslužiti vibracijski bijeli prst (VWF – *Vibration white finger*), također poznat kao *hand-arm vibration syndrome* (HAVS) ili mrtav prst, koji je zapravo sekundarni oblik Raynaudova sindroma. Nastaje kao ozljeda na poslu uzrokovana kontinuiranom uporabom vibrirajućih ručnih uređaja, strojeva i alata. Riječ je o dobro poznatoj i rasprostranjenoj ozljedi na radu, koja zahvaća na desetke tisuća radnika. Patofiziološki razvija se kao posljedica promjene građe na razini krvnih žila, živaca, mišića i zglobova, šaka, zapešća i ruku (21). Pojam „bijeli prst“ uvelo je Savjetodavno vijeće za industrijske ozljede 1970. godine. Ozljeda se može pojaviti na frekvencijama između 5 i 2000 Hz, ali najveći rizik za prste iznosi između 50 i 300 Hz. Zato u Europi postoje obavezni standardi za regulaciju i praćenje izloženosti radnika WBV-u, dok u SAD-u postoje referentni standardi, ali bez posebnih propisa (6).Važno je također napomenuti da dijelovi ljudskoga tijela kao što su kosti, mišići, masno tkivo i organi imaju rezonantnu frekvenciju (RF) te ako su pod utjecajem svoje rezonantne frekvencije dolazi do oštećenja (22, 23, 24). Rezonantna frekvencija, također zvana prirodna frekvencija, ovisi o mehaničkim svojstvima strukture koja vibrira, u ovom slučaju tkiva. Tako kosti imaju RF u rasponu od 200 do 900 Hz, a različite skupine mišića od 5 do 65 Hz. Do štetnog učinka vibracija, a time i patoloških promjena struktura, dolazi ako u jednom trenutku dođe do preklapanja frekvencije izvora vibracija i rezonantne frekvencije strukture koja je izložena. RF ovisi i o položaju osobe kada je izložena djelovanju vibracija koje se mijenjaju djelovanjem mišića. Tolerancija na vibracije može se postići ovisno o smjeru djelovanja izvora vibracija na ljudsko tijelo. Zbog različite strukturne građe ljudskoga tijela teško je bilježiti kako se vibracije prenose i pronose te kako se mijenjaju od početka vibriranja tijela do prestanka djelovanja na tijelo (25, 26, 27). Naravno, i sam karakter vibracija u vibracijskom treningu izravno utječe na zdravlje, tj. oštećenje tkiva (28). Najbolji primjer primjene prave doze vibracija je onaj kod ljudi s bolovima u donjem dijelu leđa. Kod njih vibracije definirane frekvencije i amplitude umanjuju bolove i preveniraju pojavu novih

(29). Pri razvoju uređaja za vibraciju ljudskoga tijela rabljeni su strojevi koji vibriraju u različitim smjerovima. Tako imamo uređaje koji vibriraju u X ravnini ustranu ili bočno, Y ravnini, naprijed/nazad te u Z ravnini gore/dolje. Budući da je ljudsko tijelo takve prirode da najbolje apsorbira vertikalno usmjerene vibracije, razvijena su dva tipa Z ravnine uređaja. Treba istaknuti da Z ravnina ima najveću amplitudu i odlučujuća je komponenta u generiranju i induciranju mišićne kontrakcije.

S obzirom na pomicanje u Z ravnini razvijena su dva sustava vibracijskih uređaja:

- PIVOTALNI (vertikalne sinusoidalne vibracije) – sustav u kojemu se vibrirajuća ploča „klacka“, oponaša ljudski hod (ili kao skakanje s jedne noge na drugu). Ovaj sustav ima više amplitude oscilacije i frekvenciju od 5 Hz do 35 Hz. Vibracije prenesene na glavu manje su nego u linearnom sustavu uređaja. Ovaj sustav također stvara istovjetne amplitude i frekvencije koje mišićnu aktivnost povećavaju za 60 %.

- LINEARNI (vertikalne sinkronijske vibracije) – sustav u kojem se vibrirajuća ploča giba u cijelosti u isto vrijeme gore – dolje (kao skakanje gore – dolje ili kao da se radi *push up* u jednom mjestu). Ovaj sustav ima niže amplitude oscilacije, ali veće frekvencije – od 20 Hz do 50 Hz.

Ukratko, vibracija kao mehanička stimulacija stvara sile ubrzanja koje djeluju na tijelo tako da uzrokuju kontrakciju mišića te se signal prenosi na mišićno vreteno. Vreteno odašilje signal kroz središnji živčani sustav aktivirajući motoneurone u leđnoj moždini, a oni potiču kontrakciju mišića signalima iz mozga. Zbog ove kontrole kontrakcije mišića koja nije pod utjecajem naše volje, tijelo rabi mnogo više mišićnih vlakana nego u svjesnom, voljnom pokretu što se može i registrirati pojačanom EMG aktivnošću (30, 31, 32, 33, 34). Važno je spomenuti i nazive različitih uređaja i strojeva za vibraciju koji se svakodnevno koriste, a to su Power Plate, Vibra Pro, Nemes, VibraFit, Vibrogym i druge. U svojemu smo se istraživanju koristili Power Plate tipom uređaja, kao najčešće svakodnevno rabljenoj vibrirajućoj podlozi za vježbanje.

1.3. SKELETNO MIŠIĆNO VLAKNO

Poprečnoprugasti (skeletni) mišić središte je svake vježbe jer je pod utjecajem naše volje i bez njegove snage i pomicanja vježbe ne bi ni bilo. Stoga je važno do detalja objasniti njegovu

građu i ulogu. Skeletno mišićje čini približno 40 % tjelesne mase. Osnovna građevna jedinica skeletnog mišića je skeletno mišićno vlakno koje je svako inervirano samo jednim živčanim završetkom smještenim blizu središnjeg dijela skeletnog mišićnog vlakna. Svako vlakno ima sarkolemu koja predstavlja staničnu membranu skeletnog mišićnog vlakna. Sarkolema se sastoji od prave stanične membrane zvane plazmatska membrana te od vanjskog tankog polisaharidnog sloja u kojemu se nalaze brojna tanka kolagena vlakna. Svako skeletno mišićno vlakno sadrži od nekoliko stotina do nekoliko tisuća vlakanaca zvanih miofibrili. Svaka miofibrila sadrži oko 1500 miozinskih i 3000 aktinskih niti, koje leže jedna uz drugu. Aktinske i miozinske niti su velike polimerizirane proteinske molekule odgovorne za mišićnu kontrakciju. Skeletni mišić naziva se još i poprečnoprugasti jer se aktinske i miozinske niti pod mikroskopom vide kao svijetle i tamne pruge. Svijetle pruge, koje sadrže samo aktinske niti, zovu se I-pruge jer su izotropne za polariziranu svjetlost. Tamne pruge sadrže miozinske niti i krajeve aktinskih niti koje se preklapaju s miozinskim nitima. Te se pruge zovu A-pruge jer su anizotropne za polariziranu svjetlost. Na miozinskim nitima vide se mali izdanci, nazvani poprečni mostovi. Oni, osim u središnjem dijelu, strše uzduž cijele površine miozinskih niti te kontrakcija nastaje međusobnim djelovanjem tih poprečnih mostova i aktinskih niti. Nadalje, aktinske su niti pričvršćene za tzv. Z-ploču. Od te se ploče aktinske niti protežu na obje strane i ulaze između miozinskih niti. Dio miofibrile je i sarkomera, koja se nalazi između dviju susjednih Z-ploča. Unutar mišićnog vlakna miofibrile su raspršene u matriksu, nazvanome sarkoplazma koji sadrži uobičajene stanične sastojke. Sarkoplazmatska tekućina sadrži visoku razinu kalija, magnezija, fosfata i bjelančevinskih enzima te sadržava izuzetno velik broj mitohondrija raspoređenih između miofibrila i usporedno s njima. Velik broj mitohondrija normalno je stanje mišićnog vlakna zbog velike potrebe za ATP-om (adenozin-trifosfat) koji nastaje u mitohondrijima, a neophodan je izvor energije mišićne kontrakcije. U sarkoplazmi također je smješten sarkoplazmatski retikulum, posebno je građen i vrlo je važan u nadzoru nad mišićnom kontrakcijom. Važno je napomenuti da mišići koji se brzo kontrahiraju imaju obilan sarkoplazmatski retikulum. Sustav poprečnih T-cjevčica koje su unutrašnji produžeci sarkoleme u tijesnom su dodiru sa završnim cisternama sarkoplazmatskog retikuluma koji se pak nastavlja u uzdužne cjevčice duž miofibrila. Takav raspored oko miofibrila odgovoran je za brzo pronošenje i širenje akcijskog potencijala duž skeletnog mišićnog vlakna i unutar njega, a time i za samu kontrakciju mišića (36).

Mehanizam mišićne kontrakcije odvija se na sljedeći način:

- akcijski potencijal putuje duž motoričkog živca do njegovih završetaka na mišićnim vlaknima;
- na svojemu završetku živac luči određenu količinu neurotransmitera – acetilkolina;
- acetilkolin lokalno djeluje na sarkolemu te otvara mnogo kanala reguliranih acetilkolinom koji se protežu kroz bjelančevinske molekule u sarkolemi;
- otvaranjem tih kanala omogućuje se ulaženje velike količine Na iona u unutrašnjost mišićnog vlakna;
- to potiče stvaranje akcijskog potencijala u mišićnom vlaknu;
- nakon putovanja duž sarkoleme akcijski potencijal ulazi u dubinu mišićnog vlakna čime dolazi do oslobađanja velike količine kalcijevih iona iz sarkoplazmatskog retikuluma u miofibrile;
- kalcijevi ioni potiču privlačne sile između aktinskih i miozinskih niti, što uzrokuje njihovo međusobno klizanje, odnosno dolazi do kontraktilnog procesa;
- poslije djelića sekunde kalcijeva crpka ubacuje kalcijeve ione natrag u sarkoplazmatski retikulum, gdje oni ostaju pohranjeni do novog akcijskog potencijala;
- uklanjanje kalcijevih iona iz miofibrila označava kraj mišićne kontrakcije.

Važno je istaknuti da je membranski potencijal mirovanja u skeletnom mišiću oko 80 do 90 milivolta, jednako kao i u debelim mijeliniziranim živčanim vlaknima, te da akcijski potencijal u skeletnom mišiću traje od 1 do 5 milisekundi, što je približno peterostruko dulje nego u debelim, mijeliniziranim živcima. Brzina provođenja iznosi 3 do 5 m/s što je oko 1/18 brzine provođenja u debelim, mijeliniziranim živčanim vlaknima koji inerviraju skeletne mišiće (36, 37). Sva mišićna vlakna koja inervira jedno jedino živčano vlakno zovu se motorička jedinica. Svaki motoneuron koji izlazi iz kralježnične moždine inervira veći broj mišićnih vlakana, a broj vlakana ovisi i o vrsti mišića. Mali mišići, koji brzo reagiraju i koji se moraju precizno nadzirati, u svakoj motoričkoj jedinici imaju samo nekoliko mišićnih vlakana. Veliki mišići, koji ne zahtijevaju precizan nadzor, mogu imati nekoliko stotina mišićnih vlakana u motoričkoj jedinici. Prosječno se misli da ima oko 100 mišićnih vlakana

po motoričkoj jedinici. Mišićna vlakna u svakoj motoričkoj jedinici ne drže se unutar mišića na okupu, nego se s drugim motoričkim jedinicama isprepleću i tvore mikrosnopiće od 3 do 15 vlakana. Takvo isprepletanje omogućuje da se pojedine motoričke jedinice kontrahiraju tako da kontrakcija jedne potpomaže kontrakciju druge, a ne tako da se kontrahiraju odijeljeni segmenti mišića. Osim signala iz motoneurona, za pravilnu kontrolu mišićne funkcije također je potrebna i povratna informacija kralježničnoj moždini o svakom mišiću i o njegovom trenutačnom stanju (duljini, napetosti i brzini kojom se mijenja duljina i napetost). Iz toga razloga mišići i njihove tetive obilno su opskrbljene dvjema posebnim vrstama osjetnih receptora: 1) mišićnim vretenima smještenim u trbuhu mišića (odašilju informacije o duljini mišića i brzini kojom se mijenja) i 2) Golgijevim tetivnim organima unutar mišićnih tetiva (odašilju informacije o napetosti tetiva i brzini kojom se ona mijenja). Signali iz te dvije vrste receptora služe isključivo ili gotovo isključivo samoj mišićnoj kontroli jer gotovo potpuno djeluje na podsvjesnoj razini. Isti receptori odašilju golemu količinu informacija ne samo u kralježničnu moždinu nego i u mali mozak, pa čak i u moždanu koru, te tako pomažu svim tim dijelovima živčanog sustava u njihovoj kontroli mišićne kontrakcije. Za pravilnu kontrolu mišićne funkcije potrebno je podraživanje mišića signalima iz motoneurona prednjih rogova. Oni su izvorište živčanih vlakana koji napuštaju kralježničnu moždinu i inerviraju skeletna mišićna vlakna. Dvije su vrste tih neurona; alfa-motoneuroni i gama-motoneuroni. Alfa-motoneuroni inerviraju debela mišićna vlakna. Sva ta vlakna inervirana alfa-motoneuronom nazivaju se motorička jedinica. U prednjim se rogovima nalazi i duplo manji broj gama-motoneurona koji inerviraju posebno tanka skeletna mišićna vlakna koja se nazivaju intrafuzalna vlakna te su kao takva dio mišićnog vretena. Unutar mišićnog vretena nalaze se dvije vrste vlakana. Prva su vlakna s jezgrama u vrećici, a druga su vlakna s jezgrama u lancu. Važno je također spomenuti da gama motorički živci kontroliraju statičnu i dinamičnu reakciju mišićnog vretena na način da se dijele u dvije vrste ogranaka. Prvi su gama-dinamični (gama-d) koji podražuju uglavnom intrafuzalna vlakna s jezgrama u vrećici, a drugi su gama-statični (gama-s) koji uglavnom podražavaju vlakna s jezgrama u lancu. U normalnim uvjetima, a osobito kada su gama-motorička vlakna slabo podražena, mišićna vretena neprekidno odašilju osjetne signale. Istezanjem mišićnog vretena povećava se broj impulsa, a skraćivanjem se smanjuje. Prema tome, mišićna vretena mogu slati u kralježničnu moždinu pozitivne signale i na taj način povećavati broj impulsa što je pokazatelj istezanja mišića, ili negativne signale, gdje je broj impulsa manji od normalne razine, što znači da se mišić skraćuje. Područja u mozgu koja nadziru gama motorički sustav su područja moždanog

debla (bulboretikularno facilitacijsko područje), te područje maloga mozga, bazalnih ganglija i moždane kore. Ta područja imaju osobiti udio u antigravitacijskim kontrakcijama, a s time povezano antigravitacijski mišići obiluju mišićnim vretenima što daje važnost gama motoričkom sustavu u njegovu mehanizmu prigušivanja pokreta različitih dijelova tijela pri hodanju i trčanju. Najvažnija funkcija sustava mišićnog vretena jest održavanje stabilnog položaja tijela tijekom lokomotornih radnji pri kojima je nužno da se zadrži stabilan položaj. Tada bulboretikularno facilitacijsko područje zajedno s pridruženim područjima moždanoga debla odašilju preko gama eferentnih živčanih vlakana ekscitacijske signale u intrafuzalna mišićna vlakna mišićnog vretena. Time dolazi do skraćivanja krajeva vretena i izduživanja njegova središnjeg receptorskog dijela i pojačanog odašiljanja signala vretena. U isto vrijeme aktiviraju se vretena s obje strane svakoga zgloba čime se pojačava refleksna ekscitacija skeletnih mišića te se oni napinju i suprotstavljaju jedan drugome. Vrlo osjetljivi refleks na istezanje opire se svakoj sili koja nastoji zglob pomaknuti iz trenutačnog položaja, pa je rezultat svega snažna stabilizacija zgloba. Najjednostavniji oblik funkcije mišićnog vretena jest mišićni refleks na istezanje, tzv. miotatični refleks, gdje kada god se mišić istegne, podržavanje vretena izaziva refleksnu reakciju debelih vlakana skeletnoga mišića istoga mišića. Osnova toga refleksa je monosinaptički put kod kojega proprioceptivnim živčanim vlaknom signal iz mišićnog vretena putuje u stražnji korijen kralježnične moždine. Tamo jedna grana toga vlakna ide izravno u prednji rog sive moždinske tvari gdje tvori sinapsu s motoneuronima. Od motoneurona živčana vlakna vraćaju se onom istom mišiću iz kojega potječe vlakno mišićnog vretena. U svakodnevnoj kliničkoj praksi taj refleks poznat je kao patelarni refleks, najčešće rabljen pri standardnom neurološkom pregledu. Drugi osjetni receptor, tzv. Golgijev tetivni organ, nalazi se inkapsuliran unutar mišićnih tetiva. Pomaže u nadzoru mišićne napetosti tako da odašilje informacije o napetosti tetiva i brzini kojom se ona mijenja. Svaki tetivni organ povezan je s 10 do 15 mišićnih vlakana. Napinjanjem toga maloga snopa mišićnih vlakana izaziva se podražaj Golgijeva organa. I tako dok mišićno vreteno bilježi promjenu duljine mišića, tetivni organ bilježi promjenu mišićne napetosti. Kao i mišićno vreteno, pokazuje dinamičnu i statičnu reakciju. Kada se mišićna napetost iznenada poveća dolazi do vrlo snažne dinamičke reakcije Golgijeva organa, ali se već u djeliću sekunde vrati na nižu razinu izbijanja koja je gotovo razmjerna mišićnoj napetosti, i to je statična reakcija. Tim mehanizmom Golgijev tetivni organ signalizira živčanom sustavu stupanj napetosti svakog malog segmenta u svakom mišiću. Inhibicijski refleks koji omogućuje mehanizam negativne povratne sprege, a kojom se sprječava prejako napinjanje

mišića krajnji je rezultat signala koji šalje Golgijev tetivni organ. Kada napetost mišića, a time i njegovih tetiva, postane prevelika, inhibicijski učinak iz Golgijeva tetivnog organa može biti toliko snažan da trenutačno izazove reakciju u kralježničnoj moždini i relaksaciju cijeloga mišića, a cijeli se učinak zove reakcija izduživanja. Važno je spomenuti da mišićno vreteno i Golgijev tetivni organ obavještavaju i viša motorička kontrolna središta o trenutačnim promjenama koje nastanu u mišićima (38).

U našem istraživanju bili smo fokusirani na sljedeće paraspinalne mišiće paralumblane regije, koje ukratko nabrajamo i opisujemo u nastavku:

- m. *erector spinae* – najduži je i najjači leđni mišićni masiv smješten poput široke mišićne trake u koštanoj brazdi kralježnice i između listova leđne fascije duž cijelih leđa. Polazi sa šiljatih nastavaka desetog do dvanaestog grudnog i svih slabinskih kralježaka s kriste sakralis medijane, a tuberozitas ilijake, sa stražnjeg dijela (1/5) bočnog grebena, s unutrašnje strane i lateralnog ruba stražnjeg lista leđne fascije i sa spine ilijake posterior superior. U slabinskom području mišić se dijeli u nekoliko dijelova i to najpovršnije i lateralno m. *iliocostalis,* a medijalno m. *longissimus*. Erektor spine djeluje jako snažno. Obostrana kontrakcija mišića snažno ekstendira kralježnicu, trup, vrat i glavu. Na taj način preuzima se funkcija održavanja ravnoteže jer pojedini dijelovi mišića obuhvaćaju djelovanjem većinu zglobova kralježnice. Jednostranom kontrakcijom erektora spine dolazi do pregiba kralježnice, trupa, vrata i glave u stranu i rotacije u tu stranu. Tonus m. *erectora spinae* ima značenje pri svakom koraku i promjeni položaja tijela. Inervacija erektora spine ide od stražnje grane spinalnih živaca od drugog do petog slabinskog živca. Njegova dva glavna dijela sa svojim dijelovima jesu: *iliocostalis* / *pars lumborum, thoracis et cervicalis* i *longissimus* / *pars thoracis, cervicalis et capitis*.

- m. *spinalis* / *pars thoracis, cervicalis et capitis* – parni mišić smješten medijalno od erektora spine, priljubljen je uz strane šiljatih nastavaka s kojih polazi i na koje se hvata te ga se po smještaju i hvatištima dijeli u tri dijela; prsni, vratni i za glavu. Spinalni mišić obostranom kontrakcijom ekstendira i uspravlja kralježnicu i glavu. Jednostrana kontrakcija mišića naginje kralježnicu i glavu na istu stranu. Inervacija spinalisa ide od stražnjih grana spinalnih živaca (od drugog vratnog do osmog vratnog i od prvog prsnog do osmog prsnog).

- *musculus multifidus* – jedan od transferzospinalnih mišića, maleni perast mišić, najjači je u slabinskom području. Mišićni snopići polaze sa stražnje strane križne kosti, s mamilarnog i akcesornog nastavka slabinskih kralježaka, s poprečnih nastavaka grudnih kralježaka i sa zglobnih nastavaka donjih četiriju vratnih kralježaka. Snopići ulaze koso, gore i medijalno, prebacuju se preko jednog do tri kralježaka i hvataju se na šiljaste nastavke slabinskih, grudnih i vratnih kralježaka sve do drugog vratnog kralješka. Inerviran je od stražnjih grana spinalnih živaca. Djeluje jako snažno obostranom kontrakcijom ekstendirajući kralježnicu. Jednostranom kontrakcijom sagiba i rotira kralježnicu na suprotnu stranu (39).

Ostali mišići koji dodatno stabiliziraju kralježnicu jesu:

- *musculus quadratus lumborum* – parni plosnati mišić koji oblikuje stražnji zid trbušne šupljine, a smješten je lateralno od m. *erectora spine*. Mišić je debeo oko dva centimetra, ispunjava četverokutni prostor između dvanaestog rebra, bočnog grebena zdjelične kosti i slabinskog dijela kralježnice. Mišić polazi s donjega ruba dvanaestog rebra, a dio polazi i s rebrastih nastavaka gornjih četiriju slabinskih kralježaka, niti su usmjerene prema dolje i hvataju se na unutrašnju usnu bočnog grebena i gornji rub iliolumbalne sveze, dok se dio mišićnih niti što polazi s dvanaestog rebra hvata na rebrene nastavke donjih triju slabinskih kralježaka. Inerviran je živcima od dvanaestoga prsnog preko prvog slabinskog do trećeg slabinskog živca. Ako mu je uporište na zdjeličnim kostima, onda vuče dvanaesto rebro dolje i kralježnicu na svoju stranu. Ako mu je uporište na rebrima, on podiže zdjelicu i pregiba ju na svoju stranu. Ako se u isto vrijeme kontrahiraju oba mišića dolazi do izravnavanja kralježnice pri uspravnom stavu, pri hodu. Zbog spuštanja dvanaestog rebra pomaže pri disanju, odnosno izdisaju (40).

- *musculus psoas major* – pripada mišićima zdjelice, medijalni je dio mišića *iliopsoasa*. Jedini je mišić koji polazi s kostiju trupa, a pokreće noge. Polazi s lateralnih strana trupova donjega dijela dvanaestog grudnog i gornja četiri slabinska kralješka, s odgovarajućih intervertebralnih ploča i s baza poprečnih nastavaka slabinskih kralježaka. Mišićni snopovi ne polaze izravno s trupova kralježaka već s tetivnih lukova razapetih između gornjih i donjih rubova trupova kralježaka. Mišićne niti tvore dva sloja. Prednji sloj tvore mišićni snopovi koji polaze s tetivnih lukova i putem njih

s lateralne strane trupova kralježaka. Stražnji sloj čine mišićni snopovi što polaze s poprečnih nastavaka kralježaka. Mišićni se snopovi ujedinjuju i usmjereni su dolje, malo lateralno i naprijed. Prolaze ispod kvadratusa lumobuma, pa kroz veliku zdjelicu ispred bočne kosti i napokon u brazdi poviše eminencije iliopekitineje, a iza preponske sveze prelaze na bedro. Inerviran je ograncima slabinskog živčanog spleta. Glavno djelovanje je prigibanje natkoljenice prema zdjelici u kuku. Međutim, ako je uporište u području bedrene kosti, a noga učvršćena, tada prigiba zdjelicu i slabinski dio kralježnice prema naprijed i istodobno zakreće trup na suprotnu stranu. Obostranom kontrakcijom sagiba zdjelicu i trup prema naprijed (41).

1.4. UMOR MIŠIĆA

Umor mišića je složen pojam jer predstavlja metaboličku, strukturalnu i energetsku promjenu u samome mišiću, a razlozi su tome od nedovoljne opskrbe hranjivim tvarima i kisikom do promjene učinkovitosti živčanog sustava koji inervira lokomotorni sustav te se manifestira kao pad u sposobnosti mišića da generira snagu (42). Raniji su autori potencijalna mjesta neuromuskularnog umora općenito usustavljivali u tri grupe: centralni umor (moždani umor), umor neuromuskularne veze i umor mišića (periferni umor) (44, 65). U radovima u kojima se promatra jedan mišić ili mišićna skupina pod uobičajenim nazivom „umor mišića“ misli se zapravo na „lokalni umor mišića“ (43, 65). Novija istraživanja usredotočena su na noviju klasifikaciju umora koja podrazumijeva sljedeće: NE-UMOR (*Non-Fatigue*) i UMOR MIŠIĆA (*Fatigue*). U njima UMOR MIŠIĆA predstavlja nastajanje umora tijekom mišićne kontrakcije, a NE-UMOR stanje mišića tijekom same kontrakcije koji se javlja prije početka umora mišića. Neki autori predložili su i treću grupu mišićnog umora, a to je PRIJELAZ NA UMOR (*Transition-to-Fatigue*). U prvoj fazi umora (NE-UMOR) mišić može raditi maksimalnom snagom i silom. Kada se isti taj mišić počne umarati, počinje regrutirati nova mišićna vlakna što se obično počne manifestirati kao početak prijelaza na umor (*Transition-to-Fatigue*) i dolazi do iznenadnog povećanja pucanja akcijskog potencijala motornih jedinica. Nakon tog povećanja promatra se progresija prijelaza na umor dok ne nastupi umor (*Fatigue*) (62, 64). To se može zabilježiti jer postoji pad mioelektrične snage koja dolazi iz mišića uslijed gubitka brzine provođenja unutar mišića koji se promatra („lokalizirani umor mišića“) (45). Mišićni umor također je pojava ograničene sposobnosti mišića da generira snagu te može biti uzrokovan živcima, mišićno-živčanim vezama ili samim mišićnim stanjem.

Živci su odgovorni za kontrolu kontrakcije mišića (broja, slijeda i snage mišićne kontrakcije). Većina pokreta zahtijeva silu daleko ispod one što ju mišić potencijalno može generirati. No, u izuzetno snažnim kontrakcijama, koje su blizu gornje granice ljudskih sposobnosti mišića da generira silu, živčani umor i/ili zamor (iscrpljenost), u kojem je signal živaca slab, može biti ograničavajući faktor u neutreniranih pojedinaca. Kod osoba koje počinju trenirati, mišićna mogućnost da generira silu ograničena je sposobnošću živca da održi signal visoke frekvencije. Nakon razdoblja maksimalne kontrakcije, živčani se signal smanjuje pa se i snaga kontrakcije smanjuje. Izostaje osjećaj boli ili nelagode. Mišić jednostavno „prestaje slušati“ i postupno se prestane gibati. Zbog toga treniranje snage povećava sposobnost živaca da stvore visoke frekvencije i održive signale koji omogućuju mišićima da odgovore svojom najvećom snagom. „Treniranjem živaca“ već nakon nekoliko tjedana dolazi do brzog dobivanja na snazi jer živac generira maksimalnu kontrakciju i mišić doseže fiziološku granicu. Učinci treninga povećavaju mišićnu snagu kroz miofibrilarnu i/ili sarkoplazmatsku hipertrofiju. Tada metabolički umor postaje jedini čimbenik ograničavanja kontrakcije. Na metaboličkoj razini do smanjenja sile kontrakcije dolazi zbog izravnog i neizravnog djelovanja dvaju faktora, a to su ili nedostatak hranjivih tvari, odnosno „goriva“ ili nakupljanje različitih supstrata unutar mišićne stanice. Nedostatak „goriva“, supstrata kao što su (ATP) adenozin trifosfat, glikogen i kreatin fosfat, unutar mišićnog vlakna, jedan je od uzroka metaboličkog umora. Također, metabolički umor može izazvati nakupljanje supstrata unutar mišićnog vlakna (koji blokiraju oslobađanje kalcijevih iona ili blokiraju njegovo poticanje kontrakcije), kao što su otpadne tvari, proizvedene kao rezultat mišićne kontrakcije (klorid, kalij, mliječna kiselina, adenozin difosfat, magnezijevi ioni, reaktivne vrste kisika i anorganski fosfat). Akumulacija metabolita može izravno ili neizravno uzrokovati metabolički umor unutar mišićnih vlakana zbog smetnje pri izdavanju kalcijevih iona iz sarkoplazmatskog retikuluma ili smanjenja osjetljivosti molekula aktina i miozina za kalcij. Ioni klorida djelomično inhibiraju kontrakciju mišića, sprječavajući tako kontrakciju zbog „lažne uzbune“, odnosno stvarajući male podražaje (slično mioklonusu). Ioni kalija u visokim koncentracijama također smanjuju učinkovitost mišićnih stanica, što uzrokuje grčeve i umor. Kalij se nakuplja u sustavu t-tubula i oko mišićnih vlakana kao rezultat akcijskih potencijala. Pomak u koncentraciji kalija mijenja membranski potencijal oko mišićnih vlakana. Promjena membranskog potencijala uzrokuje smanjenje otpuštanja kalcijevih iona iz sarkoplazmatskog retikuluma (46). Mliječna kiselina kao nusproizvod fermentacije poveća unutarstaničnu kiselost mišića. Zbog toga snižava osjetljivost kontraktilnoga aparata za kalcijeve ione, ali također ima za posljedicu povećanje

citoplazmatske koncentracije kalcija kroz inhibiciju pumpe koja aktivno prenosi kalcij iz stanice. To sprječava inhibirajući učinak kalija na mišićni akcijski potencijal. Mliječna kiselina ima negativan utjecaj na ione klora u mišićima, što smanjuje njihov inhibicijski utjecaj na kontrakciju i ostavlja kalijeve ione kao jedine ograničavajuće faktore koji utječu na kontrakcije mišića, iako je učinak kalija mnogo manji, nego u situaciji kada nema mliječne kiseline da ukloni kloridne ione (47). Zato ni sada nije sasvim sigurno smanjuje li mliječna kiselina umor povećavajući razinu unutarstaničnog kalcija ili povećava umor smanjenjem osjetljivosti kontraktilnih proteina na ione kalcija. Kao još jedan od uzroka umora na staničnoj razini, odnosno molekularnoj razini, spominje se konformacijska promjena Ryanodine receptora koji se nalaze na skeletnim mišićnim vlaknima, a predstavljaju glavni stanični posrednik kalcijem induciran oslobađanjem kalcija. Tijekom vježbanja dolazi do njihove konformacijske promjene što uzrokuje manjkavost u otpuštanju kalcijevih iona i doprinosi mišićnom umoru (48, 49). Mišićni umor može se bilježiti na više načina. Od invazivnih metoda kao što je EMNG koja se svakodnevno koristi kao jedna od dijagnostičkih metoda u neurologiji, preko sonomiografije (SMG – *Sonomyography*), ultrazvuka koji bilježi morfološke promjene mišića tijekom umora (50), NIRS metode (*Near-infrared spectroscopy*) kojom se monitorira koncentracija kisika tijekom mišićnog rada i umora (51,52), MMG-a (*mechanomyogram*) kojim se mjeri mehanički signal s površine mišića koji se kontrahira i bilježe vibracije unutar mišića kada se miofibrile gibaju (53) do površinske sEMG (*EMG-surface*) kojom se bilježi mišićna aktivnost snimanjem na koži iznad mišića koji radi (54, 55, 56, 62). Također se i umor mišića može dokazivati uzorkovanjem i određivanjem koncentracije laktata u mišiću iz uzoraka krvi koji se vade u unaprijed određenim vremenskim trenucima tijekom izvođenja određenog rada. Zbog samog načina uzimanja uzoraka krvi, ali i načina određivanja koncentracije laktata, nije moguće pratiti umor mišića u realnom vremenu. Nadalje, takav način mjerenja, koji se rutinski upotrebljava u sportskoj medicini, daje procjenu ukupnog umora organizma, odnosno ukupne aktivne muskulature tijela. Jedan od jednostavnijih načina za određivanje nastupa umora mišića je mjerenje vremenskog intervala tijekom kojega ispitanik može obavljati određeni rad, poput primjerice održavanja određene razine statičke (izometrijske) kontrakcije ili pak ergometrijski nametnutog opterećenja i slično. To je poznato kao „mehanička manifestacija umora mišića“ i može se definirati kao „nesposobnost održavanja zahtijevane ili očekivane sile“, stanje privremeno smanjene sposobnosti za obavljanje rada određenog intenziteta, uzrokovano upravo tim radom ili bilo koje vježbom uzrokovano smanjenje maksimalnog kapaciteta za generiranje izlazne sile ili

snage (57, 58, 59, 65). Glavna manjkavost takve metode jest da ne daje uvid u umor mišića kao kontinuirani proces biokemijskih i fizioloških promjena tijekom izvođenja određenog rada, već detektira umor mišića tek nakon njegova nastanka i zbog toga se takva metoda ne može rabiti za određivanje umora određenog mišića u situacijama kada više mišića sudjeluje u fizičkom naporu i/ili pokretu. Kontinuirano praćenje lokalnog umora mišića, najbolje se pokazalo primjenom sEMG (*superficial Electromyography*), površinske elektromiografije jer se biokemijske i fiziološke promjene tijekom umora mišića odražavaju i bilježe promjenama u mioelektričnom signalu koji se snima iznad površine kože promatranoga mišića ili mišićne skupine (60). Unatoč ograničenju primjene sEMG metode samo na mišiće koji su smješteni neposredno ispod kože, te problemu uplitanja mioelektričkih signala susjednih mišića, metoda se radi svojih prednosti rabi kao često sredstvo za određivanje lokalnog umora mišića. Prednosti su: (1) neinvazivnost, (2) primjenjivost in situ, (3) praćenje umora mišića tijekom izvođenja rada u stvarnom vremenu, (4) mogućnost praćenja umora određenog mišića i (5) korelacija s biokemijskim i fiziološkim promjenama u mišićima tijekom umaranja (61, 65). Većina istraživača za mjerenje se koristi akcelerometrom sa sEMG kožnim elektrodama, ali u našem istraživanju nije bio prikladan. Površinske EMG elektrode izrazito su prihvatljive kao alat za kliničko istraživanje mišićnoga umora kroz detekciju dinamičkih promjena u mišiću koja se kao izlazni signal bilježi kao bilo kakva fluktuacija mišićnoga rada. Da bi elektrode bile dobro postavljene, učinjena je standardizacija kroz ranija istraživanja te je postavljena standardizirana metoda postavljanja elektroda (*Standardised electrode placement method sEMG for the Non-Invasive Assessment of Muscles* – SENIAM) za neinvazivnu procjenu mišića i upotrebu elektrodnih polja (62, 63). Danas se sEMG elektrode najčešće upotrebljavaju u studijama koje mjere umor mišića te snimaju dinamičke i izometričke kontrakcije (64, 65).

1.5. KONCEPT FRAKTALA

Ljudsko tijelo kao i prirodni sustav koji ga okružuje te koji čovjek nastanjuje, u kojemu živi i kreće se osobito je složen. Zbog svoje složenosti često se nailazi na probleme u načinu mjerenja, bilo veličine ili oblika, pogotovo ako se tvorevine ne promatraju kao savršena euklidska tijela i likovi. Kada se govori o složenosti, misli se u prvome redu primjerice da promatrani oblaci nisu savršene kugle, planine i gorja nisu savršenom geometrijskom tijelu slične površine kao što ni obale koje opasuju otoke nisu krugovi. Kada je riječ o ljudskom

organizmu također se nailazi na mnogo pitanja vezanih primjerice uz karakteristični faktor umanjenja koji uređuje grananje bronhijalnog stabla te koja je stvarna površina nepravilnih, izbrazdanih tkiva kao što su primjerice girusi na velikom i malom mozgu. Nepravilne anatomske strukture kao što su bronhijalno stablo, mreža dendrita neurona ili pak provodna muskulatura srca imaju temeljnu ulogu brzog i učinkovitog prijenosa električnog potencijala duž prostorno razgranate mreže. Kao grana bazične znanosti, koja nudi novi pogled na rješavanje ove problematike ističe se nelinearna dinamika. Nelinearna dinamika svojim konceptom fraktala nudi odgovore na takva pitanja i analize sustava, objašnjavajući rezultate koji nisu u linearnoj vezi s ulaznim parametrima. Koncept fraktala utemeljen je na samosličnosti, što podrazumijeva da se duboko unutar strukture originala nalazi sadržana kopija njih samih. Prvi autori koristili su se fraktalima kao intrigantnim matematičkim zagonetkama, da bi se s vremenom fraktalne strukture polako prepoznavale u kontekstu determinističkog kaosa dinamičkih sustava (66, 67, 68, 69, 70). Teorija determinističkog kaosa, kao dio fizike, zadnjih četrdeset godina proučava ponašanje nelinearnih dinamičkih sustava koji se pod određenim uvjetima ponašaju na prividno nepredvidiv način. Dakle, riječ je o kvalitativnom proučavanju nestabilnog, neperiodičnog ponašanja u deterministčkom nelinearnom dinamičkom sustavu (71, 72, 73). Fraktali su, kao obilježje složenih nelinearnih dinamičkih sustava, nepravilne tvorbe koje karakterizira samosličnost na različitim ljestvicama mjerenja (66, 69, 74, 75). Fraktali su sazdani od podjedinica, a svaka podjedinica od podpodjedinica. Podjedinice i podpodjedinice zadržavaju oblik makroskopskog objekta te čine razgranato stablo. Važno je napomenuti da se fraktal grana na način da grana na manjim ljestvicama zadržava oblik grane na većim ljestvicama mjerenja te ako na svim ljestvicama mjerenja možemo naći kopiju početnog objekta tada kažemo da je objekt savršeno samosličan. Samosličnost može biti i približna i kao takva je svojstvena stvarnom svijetu (66, 76, 77). Osim za složene, nepravilne i samoslične strukture koncept fraktala primjenjiv je i u složenih flukutacija, koje generiraju složeni procesi kao što je ritam zdravog srca (66, 79). Sliku samosličnosti takovog procesa moguće je dobiti grafičkim prikazom flukutacije tijekom različitih vremenskih perioda. Vrijednost fraktalne dimenzije proporcionalan je samosličnoj složenosti promatranog objekta ili uzroka pojavnosti nekoga procesa te kao brojčana vrijednost predstavlja pohranjenu količinu informacija. Za razliku od fraktalne dimenzije gdje fraktalni objekt ima složeni pojam dimenzije, ranije se upotrebljavala klasična euklidska geometrija, koja poznaje topološke dimenzije geometrijskih objekata. Ona predstavlja minimalni broj koordinata koje definiraju smještaj točke na objektu. Ta točka je objekt koji

nema dijelova, topološke dimenzije jednake nuli. Da bismo definirali položaj točke na liniji, potrebna nam je samo jedna linija koja ima duljinu, a nema širinu, topološke dimenzije 1. Potrebne su nam tri koordinate da bismo definirali položaj točke u tijelu. Uz liniju imamo još i ravninu koja ima dimenziju 2, s duljinom i širinom i tijelo koje ima topološki dimenziju 3, s duljinom, širinom i dubinom (66, 76, 78). S druge strane promatranjem savršenog matematičkog primjera fraktala kroz von Kochinu krivulju možemo vidjeti da njezina dimenzija nije 1 jer položaj točaka na njoj nije moguće definirati jednom koordinatom. Dimenzija ne može biti ni 2 jer ona nije ravna. Stoga, von Kochina ima dimenziju koja je više od linije, između dimenzije 1 i 2, a manje od ravnine. To je temeljno svojstvo fraktalne dimenzije. Također je važno da fraktalna dimenzija najčešće nije cijeli broj i da je to broj koji mjeri koliko dobro fraktalni objekt ispunjava prostor u kojemu se nalazi (66, 78).

2. HIPOTEZA

Hipoteza predloženog istraživanja jest da snimanjem vibracijama inducirane električne aktivnosti paralumbalne muskulature u visokoj rezoluciji, pri čemu se dobivaju podaci koji sadrže informacije o usklađenosti rada pojedinih dijelova tih mišića kao i o promjenama njihove aktivnosti tijekom umaranja, možemo razviti metodu koja može pokazati umaranje mišića u realnom vremenu, a koja u funkcionalnoj dijagnostici lokomotornog sustava nedostaje.

3. CILJ ISTRAŽIVANJA

Glavni cilj istraživanja jest mjerenjem električnog polja koje se razvija i mijenja tijekom kontrakcije paralumbalne muskulature utvrditi u ispitanika značajke promjene električne aktivnosti tijekom izlaganja vibracijama cijeloga tijela ovisno o dobi, spolu i utreniranosti. Definiranje električno mjerljivih značajki umaranja pojedinog segmenta paralumbalne muskulature moglo bi biti polazište razvoja nove metode funkcijske dijagnostike te, za pokretljivost tijela važne, skupine mišića. S obzirom na laku primjenjivost vibrirajućih platformi i na druge ekstremitete, jednakim metodama potencijalno je moguće pristupiti i drugim dijelovima tijela, ukoliko se pokaže da je predložena metoda valjana za funkcijsku dijagnostiku lumbalnog segmenta.

4. ISPITANICI I METODE

4.1. ISPITANICI

Nakon što su ranije upoznati s ciljevima i metodom ispitivanja kroz usmeni razgovor i pisani informirani pristanak, u istraživanje su uključena 44 zdrava ispitanika-volontera, od toga 14 žena i 30 muškaraca. S obzirom na prikupljene podatke o redovitoj tjelesnoj aktivnosti, ispitanici su podijeljeni po stupnju utreniranosti paralumbalne muskulature od minimalno stupnja 2, a to se odnosi na osobe koje u posljednjih godinu dana nisu imale nikakve fizičke aktivnosti kojima bi ojačale svoje paralumblane mišiće, do stupnja 6, što bi odgovaralo osobama koje redovito treniraju ples duže od godinu dana. Tablica 4.1. u nastavku pokazuje razdiobu ispitanika prema stupnju utreniranosti s obzirom na to jesu li mlađi ili stariji od 24 godine.

Tablica 4.1. Podjela ispitanika prema stupnju utreniranosti s obzirom na dob

Stupanj utreniranosti paralumbalne muskulature (2-minimalna do 6-izvrsna)	Mlađi ispitanici (<24 godine)	Stariji ispitanici (>23 godine)	Ukupno
2	0	8	8
3	0	7	7
4	4	1	5
5	10	4	14
6	6	4	10
Ukupno	20	24	44

Skupine su tijekom ispitivanja u laboratoriju bile podijeljene tako da smo u prvoj skupini imali 8 starijih muških ispitanika od 36 do 67 godina gdje su petorica imala utreniranost 3, a trojica su imala utreniranost 2. Zatim smo imali drugu skupinu od 5 starijih ispitanica, od 48 do 65 godina i sve su imale utreniranost 2. Sljedeća skupina bila je sastavljena od 7 mlađih muških rekreativaca u dobi od 20 do 30 godina, od kojih su dvojica imala utreniranost 3, a četvorica utreniranost 4. Grupu mladih ženskih rekreativki činile su 4 ispitanice u dobi od 19 do 21 godine, sve su imale utreniranost 5. Grupu mladih nogometaša činili su muškarci od 20 do 27 godina te su svi imali utreniranost 5. Zadnje dvije grupe činilo je 10 ispitanika, muških i ženskih profesionalnih plesača, muški u dobi od 21 do 29 godina, utreniranosti 6 i ženski od 20 do 25 godina, također utreniranosti 6.

4.2. METODE

4.2.1. DOSTUPNE METODE PROCJENE AKTIVNOSTI PARALUMBALNE MUSKULATURE POD OPTEREĆENJEM

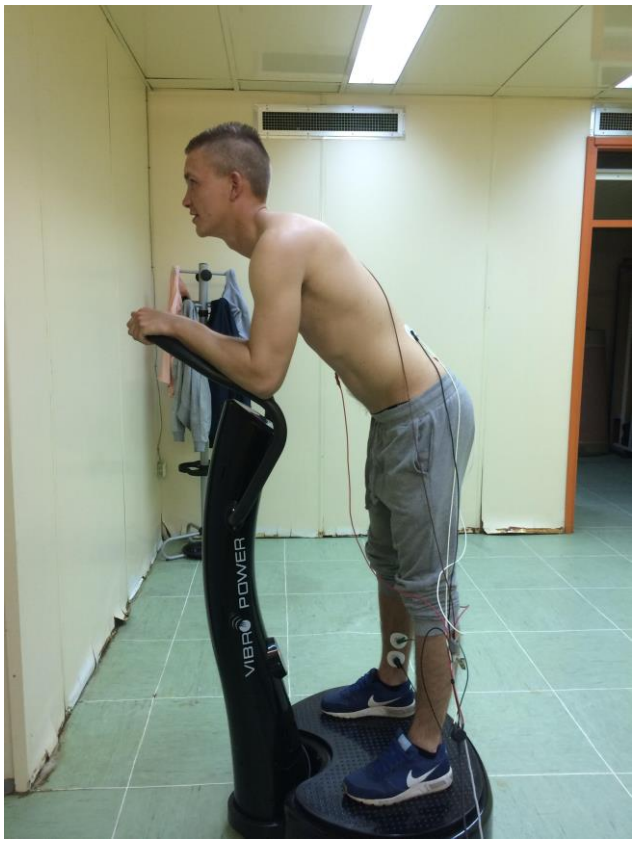
U nedostatku metode koja bi mogla mjeriti mišićnu aktivnost u malim dijelovima paralumbalne muskulature, planirano istraživanje bilo je usredotočeno na primjenu elektrofiziološkog pristupa. U radu se upotrebljavala modificirana tehnika snimanja trodimenzijskog elektrokardiograma (po Franku) visoke rezolucije, uporabom digitalnog mjernog uređaja Medilab Student Lab, pri čemu je paralumbalna muskulatura u središtu mjernog volumena umjesto srčanog mišića. Našom pilot studijom (80) i ekstrapolacijom ranijih istraživanja kretanja električnog vektora srčanog ciklusa unutar faznog prostora prsišta definirali smo ranije navedenu tehniku snimanja kao i metodu obrade podataka (81, 82). Važno je naglasiti da su raniji autori i njihova istraživanja dovela do modela elektrokardiografskog zapisa neovisnog o vektorima čiji je zaključak bio da Frankove elektrode definiraju centar električnog polja u prostoru između tri para osnih elektroda (83, 84, 85). To je polazište koje u analizi električne aktivnosti simetrično podražene paralumbalne muskulature može biti značajno u detekciji ispada aktivnosti i po slojevima (dorzalni, srednji, ventralni) i po lateralizaciji (lijevo ili desno), a moguće najvažnije po vremenu (rani ili kasni ispadi tijekom opterećenja). Dakle, ukoliko se obje strane paralumbalne muskulature istodobno i cjelovito depolariziraju i repolariziraju ne bi trebalo biti mjerljivih napona zbog mišićne aktivnosti (dobije se napon tzv. „izoelektrične linije"). No svaka razlika u aktivnosti po dubini ili lijevo – desno odražava se kao mjerljivi napon i on je veći što je veća proporcija mišića u faznom raskoraku s većinom mišića. Navedena ideja temelji se na uobičajenoj interpretaciji električne aktivnosti srca, prema kojoj se smatra da mišići razmjerno velike mase ne pokazuju bitnija električna polja ukoliko su u određenom trenutku u cijelosti depolarizirani ili u cijelosti repolarizirani. Moderni udžbenici interne i fiziološke medicine rabe vrlo slične interpretacije ECG-a (86, 87, 88, 89). Sve se one temelje na ideji da se svaki od ECG valova (P, QRS i T valovi) može shvatiti kao trodimenzionalni električni vektor, koji se kreće u prostoru i vremenu. Obično se pretpostavlja da petlja električnog vektora prati trenutačni položaj električnog vala dok se širi kroz srčani mišić. Uz EKG praćenje, određeni valovi spojeni su pomoću „izoelektrične linije" od skoro 0 milivolti, što je pretpostavljena iskonska točka svih triju valnih vektora. Iako se ta interpretacija temeljena na vektorima desetljećima s uspjehom rabila pri naučavanju osnova EKG-a, klinička praksa ipak je ostala

usredotočena na morfologiju EKG-a i karakterističnih valnih uzoraka, umjesto na vektore. To odstupanje između osnovne EKG interpretacije i kliničke medicine vrlo je dobro opisao W. Jonathan Lederer (89) u svojoj kratkoj izjavi: „Zbog toga što pomicanje naboja (tj. širećи val električne aktivnosti u srcu) posjeduje i trodimenzionalni smjer i jačinu, signal izmjeren na EKG-u je vektor. Sustav koji kliničari koriste kako bi izmjerili trodimenzionalni električni vektor srca, koji je ovisan o vremenu, može se jednostavno shvatiti i isto tako primijeniti, no ponekad ga je teže protumačiti."

4.2.2. SNIMANJE TRODIMENZIONALNOGA ELEKTROKARDIOGRAFSKOG ZAPISA VISOKE REZOLUCIJE

Nakon ulaska u laboratorij, usmenog razgovora i potpisivanja informiranog pristanka svim je ispitanicima kutanim elektrodama snimljen kontinuirani kožni potencijal u trajanju od 200 sekundi. Po uzoru na Frankovu vektorkardiografiju upotrijebljen je X, Y i Z sustav od 6 elektroda razmještenih na osi X, Y i Z tako da je koordinatni sustav centriran na lumbalnu kralježnicu. Elektrode su bile raspoređene na sljedeći način: vertikalna os Y, sredina torakalne kralježnice između lopatica i sredina sakruma; sagitalna os Z, na leđima sredina lumbalno, na pola puta između gornje i donje vertikalne elektrode, nasuprot njoj sprijeda ventralna elektroda u medijalnoj liniji; horizontalna os X, u koronarnim linijama lijevo i desno, a u visini ventralne elektrode u medijalnoj liniji. Navedeni odvodi pri takvom razmještaju postavili su paralumbalnu muskulaturu u trodimenzionalni prostor i to je omogućilo promatranje električnog polja te muskulature u svakoj tisućinki sekunde u odnosu na osi X, Y i Z. Snimak je bio registriran pomoću uređaja Biopac Student Lab (http://www.biopac.com/). Uzorkovanje je bilo vršeno s učestalošću od 1000 uzoraka u sekundi. Dobiveni podaci predstavljali su vrijednosti napona u X, Y i Z smjeru trodimenzionalnog koordinatnog sustava, dakle vrijednosti napona fronte depolarizacijskog vala u prostoru u svakoj tisućinki sekunde. U postavkama uređaja za primijenjene kablove i elektrode koristili su se sljedeći uobičajeni parametri: pojačanje 1000 puta bez otklona, filtar koji propušta iznad 0,05 Hz i prigušivanje 0,7 iznad 100 Hz. Električno polje koje su razvijali paralumbalni mišići ovisi o njihovoj električnoj aktivnosti u promatranoj tisućinki sekunde, pa stoga ako su naponi mali nema mnogo razlike u električnom polju promatranih mišića, a ako je napon velik, jedan dio mišića razlikuje se od ostatka u stupnju depolarizacije. Sam pokus započeo je lijepljenjem i fiksacijom kožnih elektroda iznad ranije opisanih točaka koje opisuju koordinatni sustav

centriran na lumbalnu kralježnicu, a bit će povezane s Biopac Student Lab uređajem i stolnim računalom. Snimanje se vršilo dok je ispitanik na vibrirajućoj podlozi (Power Plate – model VIBRO POWER) stajao u nagnutom položaju, tako da je kut između podlaktica i nadlaktica iznosio cca 90 stupnjeva, a kut između trupa i natkoljenica cca 120 stupnjeva te je bio u normalnom raskoračnom stavu. Snimanje je trajalo 200 sekundi s frekvencijom od 1000 Hz (uređaj postavljen na operaciju 6). Cijelo vrijeme snimanja ispitanici su bili bez aktivnog mišićnog rada. Po završetku snimanja s ispitanika se odstrane kutane elektrode i time pokus završava (slika 4.1.).



Slika 4.1. Položaj ispitanika na vibrirajućoj podlozi za vrijeme snimanja

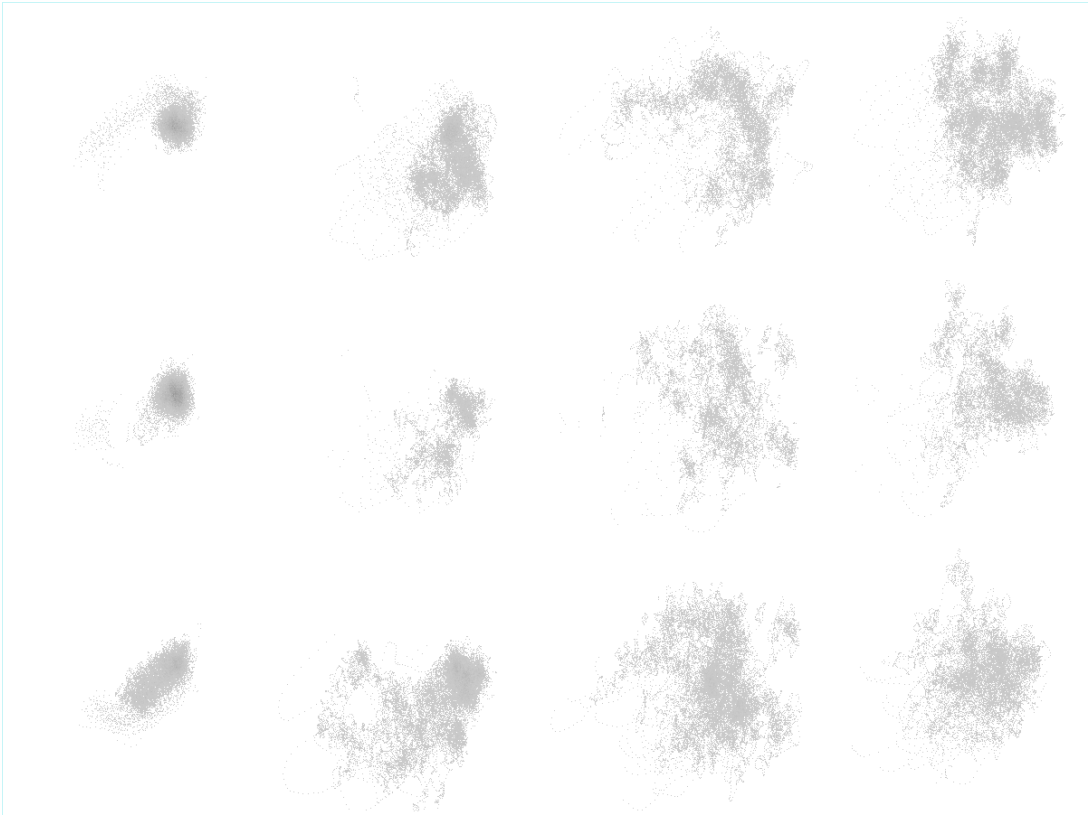
4.2.3. BILJEŽENJE I POHRANA PODATAKA SNIMANJA

Svi u visokoj rezoluciji snimljeni podaci pohranjeni su u računalu te na poseban način procesuirani izvorno pisanim programom (Program Dinjar 2.03., autor programa; prof. dr. sc. Sven Kurbel, 2013., Osijek, RH). Izvorno pisani program u zapisu prepoznaje R zupce i odbacuje ih 60 milisekundi prije i 60 milisekundi nakon vrha R zupca, kako električna

aktivnost srca ne bi narušila analizu električne aktivnosti mišića. To se čini jer su naponi QRS kompleksa najvažnija električna smetnja od strane srca dok su amplitude P i T valova male kada se snima s takvim rasporedom elektroda. Takav filtrirani zapis bez QRS-a dalje je poslužio za analizu izvorno pisanim programima na taj način da se od izmjerenih napona stvorio slikovni prikaz (bmp) razdiobe u frontalnim ravninama različite dubine, pri čemu su se odvojeno promatrali podaci u vremenu. S obzirom na položaj u trodimenzionalnom prostoru, podaci su bili promatrani tako da je prvo ishodište koordinatnoga sustava bilo postavljeno u aritmetičku sredinu svih izmjerenih napona. Tako je oblak vrijednosti sazdan od više desetina tisuća milisekundi od kojih svaka ima vrijednost jedne točke u tom oblaku. Podaci su nakon toga podijeljeni u kvadrante i u slojeve oblaka radi lakšeg prikaza i razumijevanja. Svi ispitanici bili su promatrani u frontalnoj ravnini, a imali su tri sloja; ventralni, intermedijalni i dorzalni sloj. Navedeni slojevi dobiveni su tako da je oblak podataka podijeljen s obzirom na udaljenost duž osi Z. Pretvorbom je dobiven generirajući oblik sloja. Generirajući oblik sloja kod većine ispitanika izgledao je kao oblak točkica koji nekada podsjeća na leptira, a nekada na bananu (slika 4.2. i 4.3.). Generirajući oblik pokazuje ponašanje mišića u grafičkom prikazu tijekom stajanja na vibrirajućoj podlozi, dok izrazito radi paralumbalna muskulatura i ispitanik ne mijenja položaj tijekom ispitivanja. Podaci su podijeljeni u četiri razdoblja kako bi se promjenom izgleda oblaka svih triju prije navedenih slojeva lako moglo vizualno predočiti umaranje mišića.



Slika 4.2. Prikaz generirajućih oblika slojeva u ispitanika koji na vibrirajućoj podlozi stoji uspravno

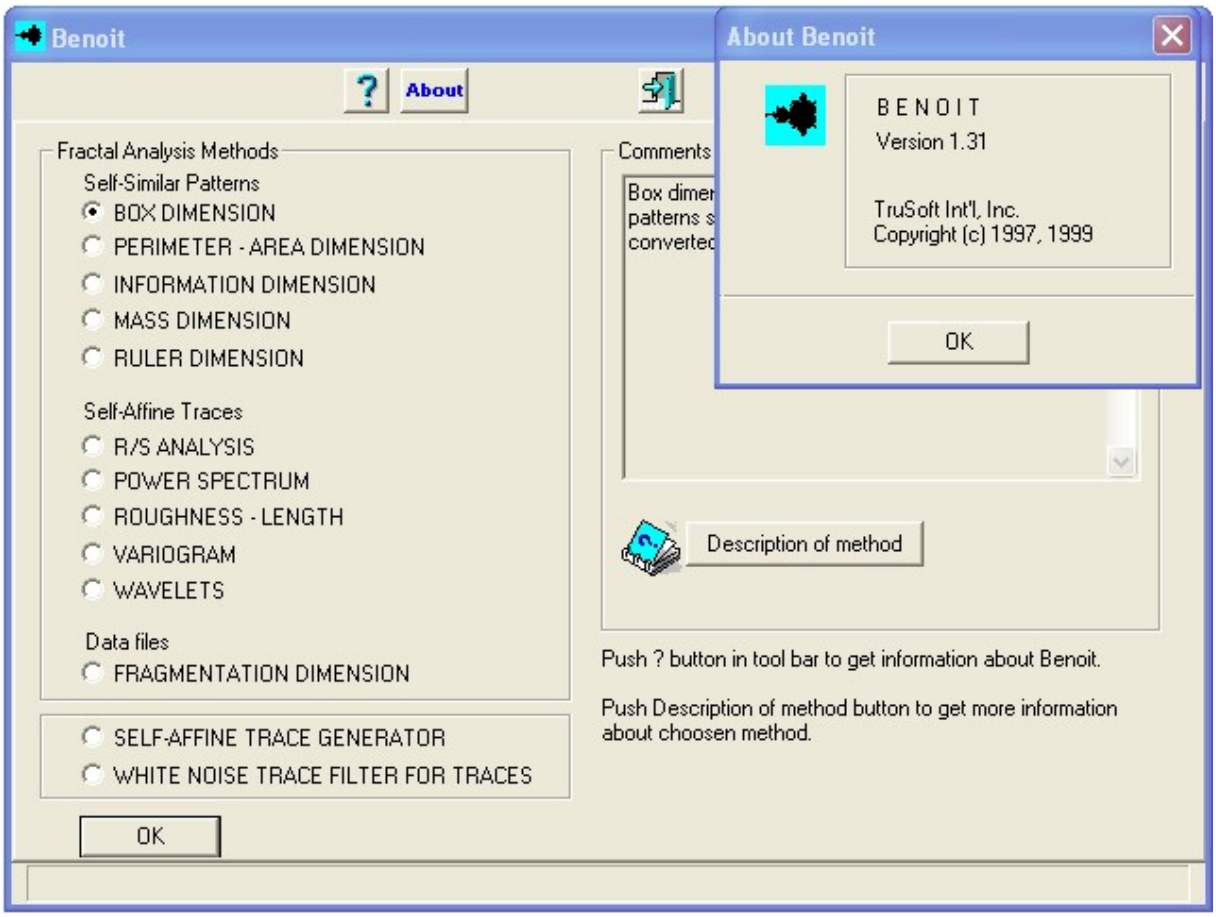


Slika 4.3. Prikaz generirajućih oblika slojeva u ispitanika koji na vibrirajućoj podlozi stoji nagnut naprijed

4.2.4. PRIPREMA PODATAKA ZA STATISTIČKU OBRADU IZRAČUNOM FRAKTALNE DIMENZIJE

Nakon što je pilot studija pokazala da je vizualizacijom oblaka podataka u tri ravnine jasno vidljivo da postoji promjena oblaka podataka tijekom kontinuiranog izlaganja tijela vibracijama zbog aktivacije paralumbalne muskulature, počela se tražiti adekvatna matematička metoda kojom bi se moglo kvantificirati uočene promjene razdiobe podataka. Kako je zapravo riječ o nizu numeričkih podataka u tri osi koje su međusobno razmaknute tisućinkom sekunde odabir pogodne metode nije jednostavan. Prvi problem predstavljao je artefakt srčane aktivnosti koji je najviše izražen kroz veliku naponsku promjenu uzrokovanu QRS kompleksom u EKG krivulji. To je informatički riješeno tako da se dio EKG zapisa oko R zupca izbacivao iz svih vremenskih serija i jednakim algoritmom. Sljedeći problem bio je problem ravnine. Kao što je bilo objašnjeno u pilot studiji (80), kako se ne bi zbog sumiranja trodimenzionalnih podataka u dvodimenzionalnu ravninu izgubila informacija o dubini, podaci su umjetno podijeljeni u tri sloja. Međutim, ukoliko tako pokušamo prikazati vremensku seriju za pisanje podataka neminovno je da će se niz vremenske serije vrlo značajno narušiti. Iz navedenog razloga, od podjele na tri ravnine moralo se odustati jer je osnovna postavka bila da se podaci u što je moguće manjoj mjeri mijenjaju. Nakon dosta pokusa s različitim metodama, odlučili smo se za primjenu metode izračuna fraktalne dimenzije za vremenske serije koje su dostupne u poznatom programu naziva Benoa (BENOIT, version 1.31), a koji se pokazao kao izuzetno dobar kod izračuna koji su upotrebljavali raniji autori (82). Program je prikazan slikom 4.4. Od pet opcija za analizu vremenskih serija namjerno su izabrane dvije. Za analizu istih podataka, izabrana je opcija R/S algoritam koja predstavlja uobičajeno računanje fraktalne dimenzije, a druga opcija je *wavelet* transformacija (90, 91). Razlog za odabir tih dviju metoda bio je što je R/S algoritam opcija izračuna uobičajena u analizi fraktala koji nisu vremenske serije, dok je druga metoda, *wavelet* transformacija, također u sve većoj upotrebi u analizi medicinskih prikaza i sličnim biomedicinskim aplikacijama, a posebno je zanimljiva zato što daje u velikom dijelu analiziranih podataka bitno drukčije vrijednosti fraktalne dimenzije od uobičajenog algoritma. Ostale dostupne metode (*power spectrum, roughness-lenght, variogram*) najčešće daju slične rezultate fraktalne dimenzije osnovnom algoritmu koji smo primijenili. Podaci su priređeni izračunom fraktalne dimenzije na način da su izdvojeni podaci za os X, os Y i os Z. Posebno su izračunata dva vektora koji prikazuju kretanje točke u trodimenzionalnom prostoru u odnosu na položaj u ranijoj milisekundi. Na taj je način za svako mjerenje priređeno pet

arhiva u kojima su izdvojeni podaci za X, Y, Z i dva vektora te su za sve navedene arhive izračunate dvije vrijednosti fraktalne dimenzije.



Slika 4.4. Prikaz programa Benoit za izračun fraktalne dimenzije

4.2.5. DEFINIRANJE NAČINA MJERENJA ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE

U istraživanju je definirano pet načina mjerenja električne aktivnosti paralumbalne muskulature. Dva su načina vektorska, koje ćemo opisati kasnije u tekstu. Tri su načina definirana tako da su izdvojeni kretanjem električnog polja, bilo duž osi X (lijevo – desno), duž osi Y (gore – dolje) ili duž osi Z (naprijed – nazad). Program koji je analizirao podatke (Program Dinjar 2.03., autor programa; prof. dr. sc. Sven Kurbel, 2013., Osijek, RH) iz svakoga je, nakon uklanjanja QRS kompleksa, stvorio pet odvojenih zapisa gdje su po fazama opterećenja, odnosno u četvrtinama opterećenja prikupljeni podaci za taj načina mjerenja. U

radu su računata dva različita vektora. Prvi je vektor izračunat u odnosu na aritmetičku sredinu oblaka podataka tako da su vrijednosti u svakoj milisekundi X, Y i Z bile umanjene za aritmetičku sredinu svih vrijednosti X, Y i Z pa je tako dobivena udaljenost od aritmetičkog središta oblaka podataka. Te razlike (delta X, delta Y i delta Z) potrebne su za računanje dijagonale kvadra u faznom prostoru koji predstavlja udaljenost u električnom polju izraženu u milivoltima. Drugi vektor nije bio povezan s udaljenošću u faznom prostoru, odnosno s nekom apstraktnom točkom kao što je aritmetičko središte oblaka, već je bio usredotočen na kretanje električnog polja tijekom vremena. Zbog toga je u ovom istraživanju nazvan temporalnim vektorom, a dobiven je tako što su koordinate u određenom vremenu, tj. u pojedinoj milisekundi oduzete od koordinata u prethodnoj milisekundi i ta je udaljenost u X, Y i Z osi ponovno upotrijebljena za računanje dijagonale kvadra, a rezultate je predstavljao pomak u jednoj milisekundi, izraženoj u milivoltima. Iz svega proizlazi da je temporalni vektor brzina promjene električnog polja u milisekundi. Kada je riječ o vektorima u električnom signalu koji se promatra bilo u ravnini ili u prostoru, obično se računa vektor iz neke referentne točke, a to može biti ishodište koordinatnih sustava ili u našem slučaju aritmetičkog središta oblaka podataka. Upravo su zato računata baš ta dva vektora. Treba imati na umu da vektor samo odražava razdiobu u ravnini, odnosno u faznom prostoru, a ne opisuje stvarno kretanje, jer električno polje ne kreće u svakoj milisekundi iz te referentne točke do točke mjerenja već putuje u faznom prostoru između točaka mjerenja. U ovome istraživanju vektor koji povezuje točke mjerenja u slijedu naziva se temporalnim vektorom, a vektor koji se odnosi na referentnu točku, odnosno aritmetičko središte oblaka podataka naziva se centrifugalni vektor.

4.3. STATISTIČKA OBRADA PODATAKA

Pri statističkoj obradi podataka primijenjeno je sljedeće:

- za izračun fraktalnih dimenzija upotrijebljen je programski paket TruSoft Int'l, Inc. (1997, 1999) Benoit, ver. 1.31 (www.trusoft.netmegs.com)
- za statističku obradu dobivenih podataka, izradu tablica i grafikona upotrijebljeni su statistički programski paketi STATISTICA (*data analysis software system*), *version* 10 (StatSoft, Inc. 2011) www.statsoft.com

- razlike u vrijednosti kvantitativnih značajki više nezavisnih uzoraka analizirane su Kruskal-Wallis testom.

U radu je također rabljena metoda maksimizacije očekivanja (*EM clustering*), koja se kod ranijih istraživanja i analiza kompleksnih distribucija pokazala izrazito učinkovita. Kao što je vidljivo iz literature neki su se autori koristili EM klasteriranjem primjenom v-fold križnih valorizacijskih algoritama za automatsko određivanje broja klastera u podacima (dobivenih Statistica programom), pri čemu je *EM clustering* algoritam približavao promatrane distribucije vrijednosti mješavinom distribucija u različitim klasterima (92, 93). Važno je spomenuti da je *EM clustering* iterativna metoda za pronalaženje maksimalnih vjerojatnosti ili najvećih aposteriori procjena parametara u statističkim modelima, gdje model ovisi o neočekivanim latentnim varijablama. EM iteracija izmjenjuje se između izvođenja očekivanog koraka (E), što stvara funkciju za očekivanje logaritamske vjerojatnosti koja se procjenjuje upotrebom trenutačne procjene parametara, i koraka maksimizacija (M), koji izračunava parametre koji povećavaju očekivanu logaritamsku vjerojatnost nađenu u koraku (E). Te procjene parametara zatim se upotrebljavaju za određivanje raspodjele latentnih varijabli u sljedećem E koraku. EM algoritam koristi se za pronalaženje lokalnog maksimuma vjerojatnosti parametara statističkog modela u slučajevima gdje se jednadžbe ne mogu izravno riješiti. Ti modeli tipično obuhvaćaju latentne varijable uz dodatak nepoznatih parametara i poznatih promatranja podataka. To znači da ili postoje vrijednosti koje nedostaju među podacima, ili se model može formulirati jednostavnije pretpostavljajući postojanje daljnjih nepromatranih podatkovnih točaka. Na primjer, model mješavine može se jednostavnije opisati pretpostavljajući da svaka promatrana točka ima odgovarajuću nepromatranu podatkovnu točku ili latentnu varijablu, koja određuje komponentu mješavine kojoj pripada svaka podatkovna točka. Pronalaženje rješenja maksimalne vjerojatnosti obično zahtijeva uzimanje derivacija funkcije vjerojatnosti, uzimajući u obzir sve nepoznate vrijednosti, parametre i latentne varijable, te istodobno rješavanje dobivenih jednadžbi. U statističkim modelima s latentnim varijablama to je obično nemoguće. Umjesto toga, rezultat je obično skup međusobno oprečnih jednadžbi u kojima rješenje parametara zahtijeva vrijednosti latentnih varijabli i obrnuto, ali umetanje jednog skupa jednadžbi u drugi potom stvara nerješivu jednadžbu. EM algoritam proizlazi iz zamisli da se ta dva niza jednadžbi mogu riješiti numerički na sljedeći način. Jednostavno treba odabrati proizvoljne vrijednosti za jedan od ta dva skupa nepoznanica i iskoristiti ih za procjenu drugog skupa. Nakon toga te nove vrijednosti treba upotrijebiti kako bi se pronašla bolja procjena prvoga skupa, a potom ih

treba izmjenjivati sve dok vrijednosti rezultata ne konvergiraju u fiksnim točkama. Nije pretjerano očigledno da će to funkcionirati, ali može se dokazati da u tom kontekstu to uistinu funkcionira i da je izvedenica vjerojatnosti (relativno blizu) nule u toj točki, što zauzvrat znači da je ta točka ili maksimum ili točka sedla. Općenito se mogu pojaviti višestruki maksimumi, bez ikakvog jamstva da će globalni maksimum moći biti pronađen. Neke vjerojatnosti također u sebi imaju određene singularnosti, tj. besmislene maksimume. Na primjer, jedno od rješenja koje se može pronaći pomoću EM-a kod modela mješavine uključuje postavljanje jedne od komponenata tako da nema varijacija, dok bi srednji parametar za istu komponentu trebao biti jednak jednoj od podatkovnih točaka (94).

5. REZULTATI

5.1. REZULTATI PILOT STUDIJE VIZUALIZACIJE PROMJENE ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA

Na slikama 5.1. do 5.4. prikazani su rezultati nekih od naših ispitanika i to na način da su mjerenja rađena tijekom standardnog opterećenja trajanja 200 s, dakle prikupljeno je 200 000 pozicija električnog polja u faznom prostoru po ispitaniku. Izrezani su dijelovi zapisa koji odgovaraju QRS kompleksima srčane električne aktivnosti. Preostale točke podijeljene su vremenski u četiri faze po 50 s i u tri sloja: dorzalni prostor, srednji prostor i ventralni prostor mjernog volumena. Tako je na slikama 5.1. do 5.4. prikazano po 12 malih oblaka točaka, pri čemu su redovi slojevi prostora, a stupci predstavljaju faze u vremenu (prvih, drugih, trećih i četvrtih 50 s).



Slika 5.1. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 27 godina



Slika 5.2. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 25 godina



Slika 5.3. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 22 godine



Slika 5.4. Prikaz promjene u obliku i gustoći oblaka točaka, po sloju faznog prostora i tijekom napora u muškog ispitanika starog 21 godinu

5.2. REZULTATI ANALIZE FRAKTALNOSTI ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA

Analiza prikupljenih podatka provedena je primjenom više različitih metoda. Iz sirovih podataka električne aktivnosti paralumbalne muskulature tijekom 200 s izlaganja vibracijama prvo su uklonjeni QRS kompleksi srčane aktivnosti, a zatim je po četvrtinama trajanja (50 s) izdvojeno po pet posebnih zapisa za daljnju analizu (zapis osi X, Y, Z, zapis temporalnog i centrifugalnog vektora). Po jednom ispitaniku tako je nastalo 20 zapisa (četiri četvrtine od kojih svaka ima pet zapisa). Za svaki zapis izračunata je fraktalna dimenzija po metodi R/S analize i *wavelet* transformacije, pa je svaki ispitanik dobio dvije različite vrijednosti fraktalne dimenzije za svaki od 20 zapisa. Vrijednosti fraktalne dimenzije nadalje su rabljene kao brojčani pokazatelj složenosti variranja izmjerenih vrijednosti u pojedinom zapisu.

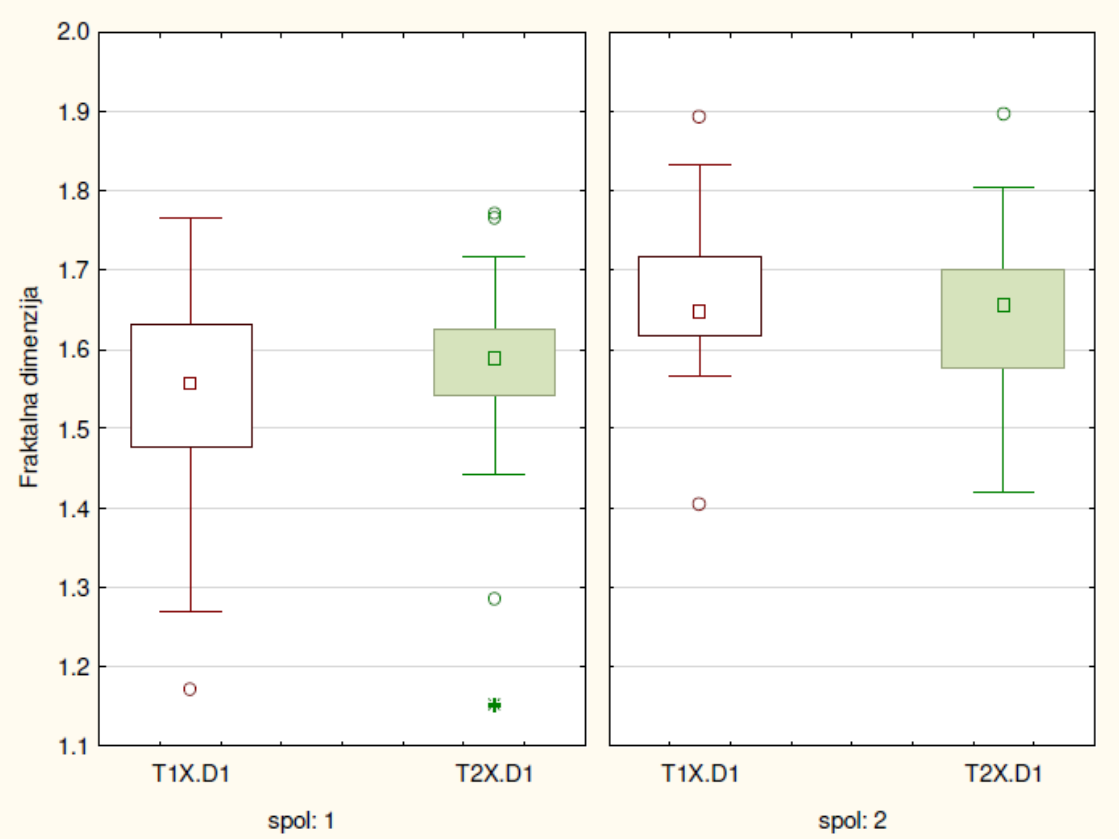
5.2.1. RAZLIKE U FRAKTALNOJ DIMENZIJI OVISNO O SPOLU I UTRENIRANOSTI PARALUBALNE MUSKULATURE

Prvi dio analize bilo je utvrđivanje postojanja razlika u fraktalnim dimenzijama ovisno o spolu i utreniranosti paralumbalne muskulature. Iz tablice 5.1. možemo vidjeti razlike u vrijednostima R/S fraktalne dimenzije ovisno o spolu i stupnju utreniranosti paralumbalne muskulature.

Tablica 5.1. Prikaz ovisnosti R/S fraktalne dimenzije prikupljenih podataka o spolu i utreniranosti

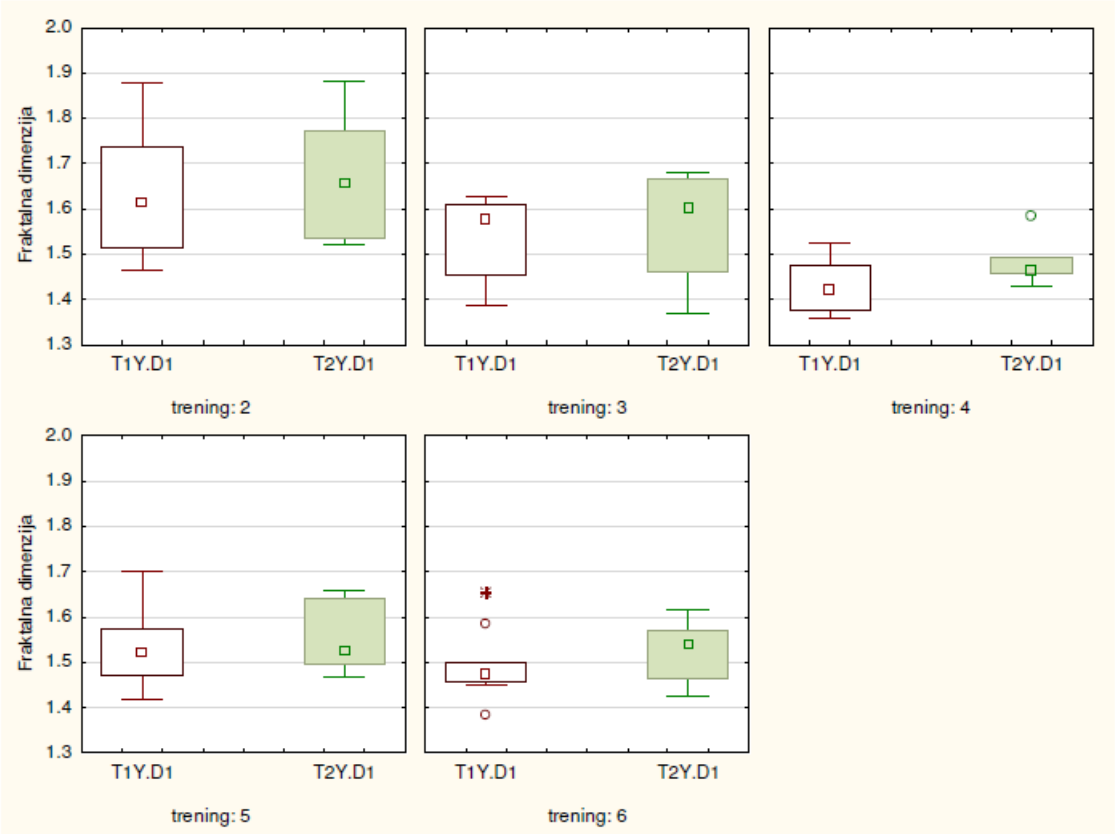
<table>
<tr><td colspan="2" rowspan="3">Razdioba vrijednosti R/S fraktalne dimenzije električne aktivnosti tijekom 4 faze opterećenja po spolu i treniranosti ispitanika</td><td colspan="5">Načini mjerenja električne aktivnosti paralumbalne muskulature</td></tr>
<tr><td colspan="3" rowspan="2">Položaj mjerenja duž osi faznog prostora (mV)</td><td colspan="2">Vektor faznog prostora (mV)</td></tr>
<tr><td>temporalni</td><td>centrifugalni</td></tr>
<tr><td colspan="2">Pokazatelji (Kruskal-Wallis (p))</td><td>X (lijevo-desno)</td><td>Y (gore-dolje)</td><td>Z (naprijed-nazad)</td><td>od prethodnog mjerenja</td><td>od aritmetičkog centra oblaka</td></tr>
<tr><td rowspan="4">Razdioba po spolu (M ili Ž)</td><td>1. četvrtina</td><td>0,004</td><td rowspan="4">>0,05</td><td>0,007</td><td><0,001</td><td><0,001</td></tr>
<tr><td>2. četvrtina</td><td>0,05</td><td>0,01</td><td>0,007</td><td>0,002</td></tr>
<tr><td>3. četvrtina</td><td rowspan="4">>0,05</td><td>0,01</td><td>0,004</td><td rowspan="2">>0,05</td></tr>
<tr><td>4. četvrtina</td><td><0,001</td><td>0,007</td></tr>
<tr><td rowspan="4">Razdioba po utreniranosti (od 2 do 6)</td><td>1. četvrtina</td><td>0,02</td><td rowspan="4">>0,05</td><td rowspan="2">>0,05</td><td rowspan="4">>0,05</td></tr>
<tr><td>2. četvrtina</td><td>0,03</td></tr>
<tr><td>3. četvrtina</td><td rowspan="2">>0,05</td><td>0,01</td></tr>
<tr><td>4. četvrtina</td><td>>0,05</td></tr>
</table>

Iz tablice je razvidno da je razdioba po spolu postojala u smjeru X (lijevo – desno) samo za mjerenje u prvoj i drugoj četvrtini snimanja. Po smjeru Y (gore – dolje) nije postojala razlika po spolu. Po smjeru Z (naprijed – nazad) uočena je razlika po spolu, najvjerojatnije uzrokovana anatomskim razlikama u građi zdjelice i jačini muskulature. Promatrajući vektore, vidljivo je da se temporalni vektor (brzina promjene električnog polja) u sve četiri faze mjerenja značajno razlikuje po spolu, dok se centrifugalni (udaljenosti od središta oblaka podataka u faznom prostoru) razlikovao samo u prve dvije četvrtine vremena. Promatrajući razdiobu po stupnju utreniranosti, jedine tri značajne razlike uočene su u smjeru Y (gore – dolje) u prve dvije četvrtine te u temporalnom vektoru tijekom treće četvrtine.
Da bismo bolje shvatili uočene razlike, prikazane su grafikonima koji slijede.



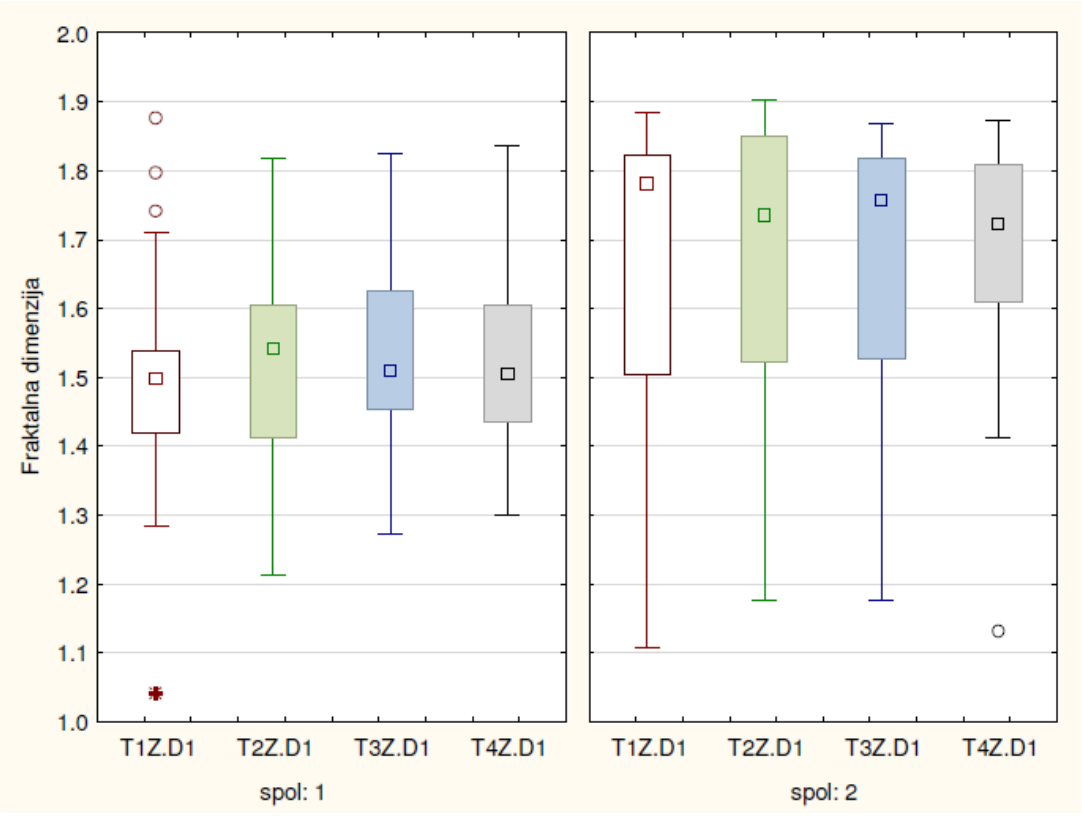
Slika 5.5. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika R/S fraktalne dimenzije po osi X ovisna o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – prva četvrtina izlaganja, T2 – druga četvrtina izlaganja, X – os faznog prostora, D1 – R/S izračun fraktalne dimenzije).

Grafikon na slici 5.5. prikazuje razliku razdiobe vrijednosti R/S fraktalne dimenzije po osi X u prvome i drugome vremenu ovisno o spolu iz koje možemo vidjeti da su muškarci u prvoj četvrtini napora bili znatno manje fraktalne dimenzije u odnosu na drugu četvrtinu. Drugim riječima, fraktalna dimenzija muškaraca u prvoj četvrtini bila je razmjerno niska i širokoga raspona, da bi zagrijavanjem, tijekom druge četvrtine izlaganja vibracijama došlo do porasta fraktalne dimenzije i suženja raspona vrijednosti. Kod ispitanica došlo je do obrnute situacije, početna vrijednost bila je viša nego kod muškaraca i razmjerno uskog raspona, međutim, daljnjim izlaganjem naporu došlo je do sniženja medijana fraktalne dimenzije i proširenja raspona.



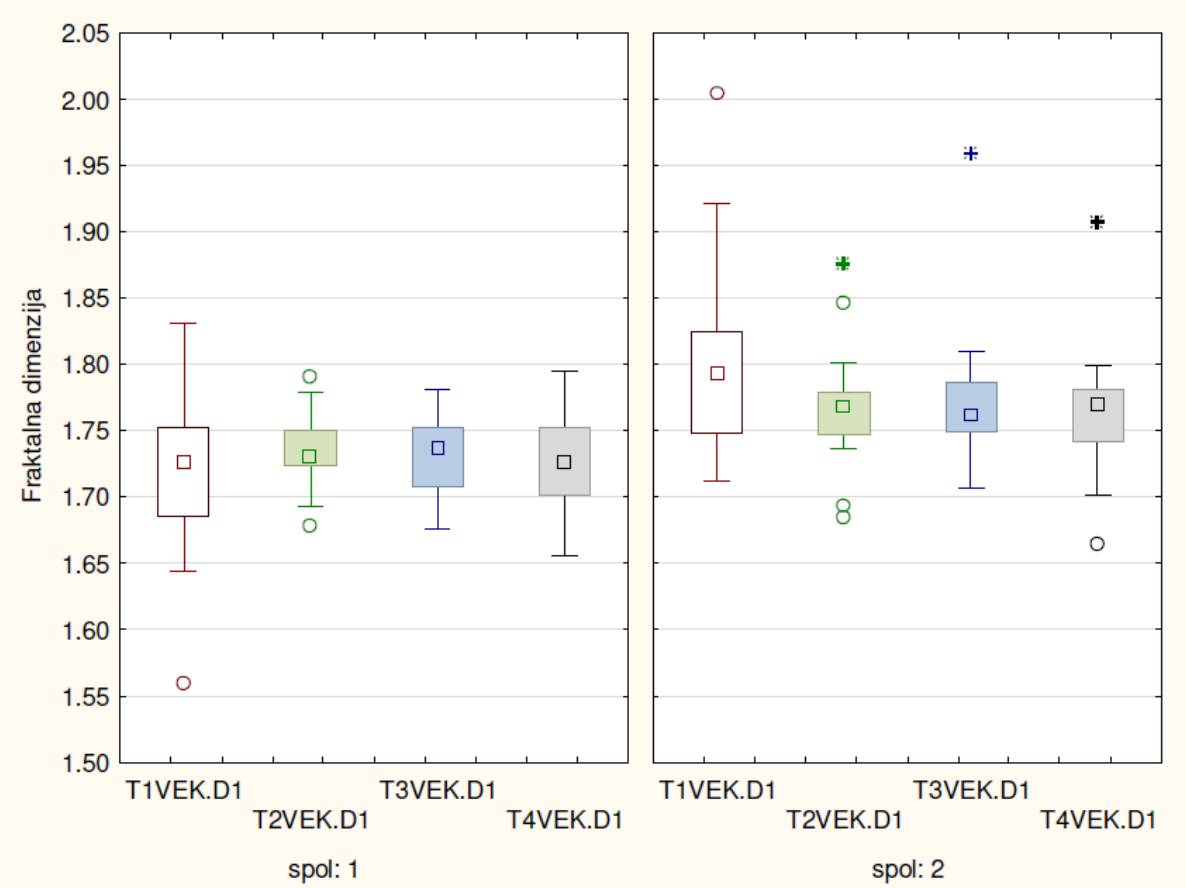
Slika 5.6. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika R/S fraktalne dimenzije po osi Y ovisno o stupnju utreniranosti (trening 2 – 6 – utreniranost 2. – 6. stupnja, T1 – prva četvrtina izlaganja, T2 – druga četvrtina izlaganja, D1 – R/S izračun fraktalne dimenzije, Y – os faznog prostora).

Grafikonima na slici 5.6. pokazujemo kako stupanj utreniranosti utječe na R/S fraktalnu dimenziju električne aktivnosti u smjeru gore – dolje (os Y) u prvoj i drugoj četvrtini vremena izlaganja. Razvidno je da najslabije utrenirani ispitanici (stupanj utreniranosti 2), tijekom prve dvije četvrtine izlaganja, imaju razmjerno visoke vrijednosti fraktalne dimenzije koje se krajem izlaganja još povećavaju, dok ispitanici koji su visoko utrenirani (stupanj utreniranosti 5 i 6), imaju niske vrijednosti mnogo užega raspona tijekom izlaganja te se raspon vrijednosti fraktalne dimenzije donekle proširuje u drugoj četvrtini izlaganja. Ispitanici trećeg stupnja utreniranosti ponašaju se slično neutreniranima, a ispitanici četvrtog stupnja po utreniranosti su slični dobro utreniranim ispitanicima.



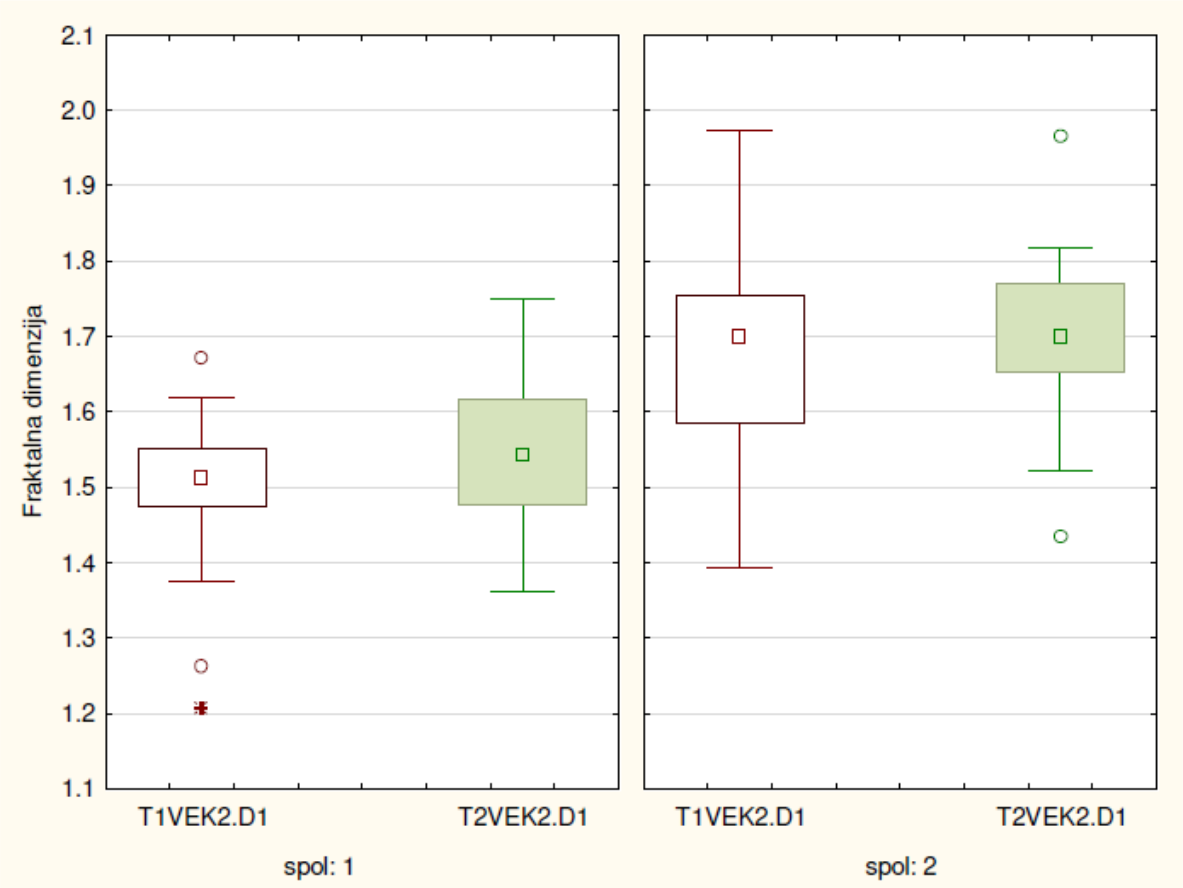
Slika 5.7. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlika u R/S fraktalnoj dimenziji ovisnoj o spolu u smjeru osi Z (naprijed – nazad) tijekom četiri faze izlaganja vibracijama (spol 1 – muški spol, spol 2 – ženski spol, T1 – T4 – prva do četvrta četvrtina izlaganja, Z – os faznog prostora, D1 – R/S izračun fraktalne dimenzije).

Iz grafikona na slici 5.7. može se vidjeti, kod muških ispitanika (spol 1), da se razmjerno niska fraktalna dimenzija tijekom napora povisuje i to u drugoj četvrtini opterećenja, da bi se kasnije lagano snižavala i u četvrtoj četvrtini postala vrlo slična početnoj. Bitno drukčiju situaciju imamo u ispitanica (spol 2), gdje je fraktalna dimenzija visoka i širokog raspona u prvoj četvrtini, kasnije se postupno snižava i sužava tijekom izlaganja naporu, s time da su R/S vrijednosti fraktalnih dimenzija kroz sve četiri četvrtine bitno više nego kod muškaraca.



Slika 5.8. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike u fraktalnoj dimenziji temporalnoga vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – T4 – prva do čevrta četvrtina izlaganja, VEK – temporalni vektor, D1 – R/S izračun fraktalne dimenzije).

Slika 5.8. prikazuje razlike u fraktalnoj dimenziji R/S izračunom temporalnog vektora ovisno o spolu. U muškaraca opterćenjem dolazi do suženja rasapa vrijednosti fraktalne dimenzije oko gotovo nepromijenjenog medijana da bi u zadnjoj četvrtini rasap vrijednosti postao sličan rasapu u prvoj četvrtini. Kod ispitanica su vrijednosti fraktalne dimenzije u prvoj četvrtini više nego u muškaraca i nastavkom opterećenja pokazuju umanjeni medijan i umanjeni rasap, bez povratka na situaciju u prvoj četvrtini.



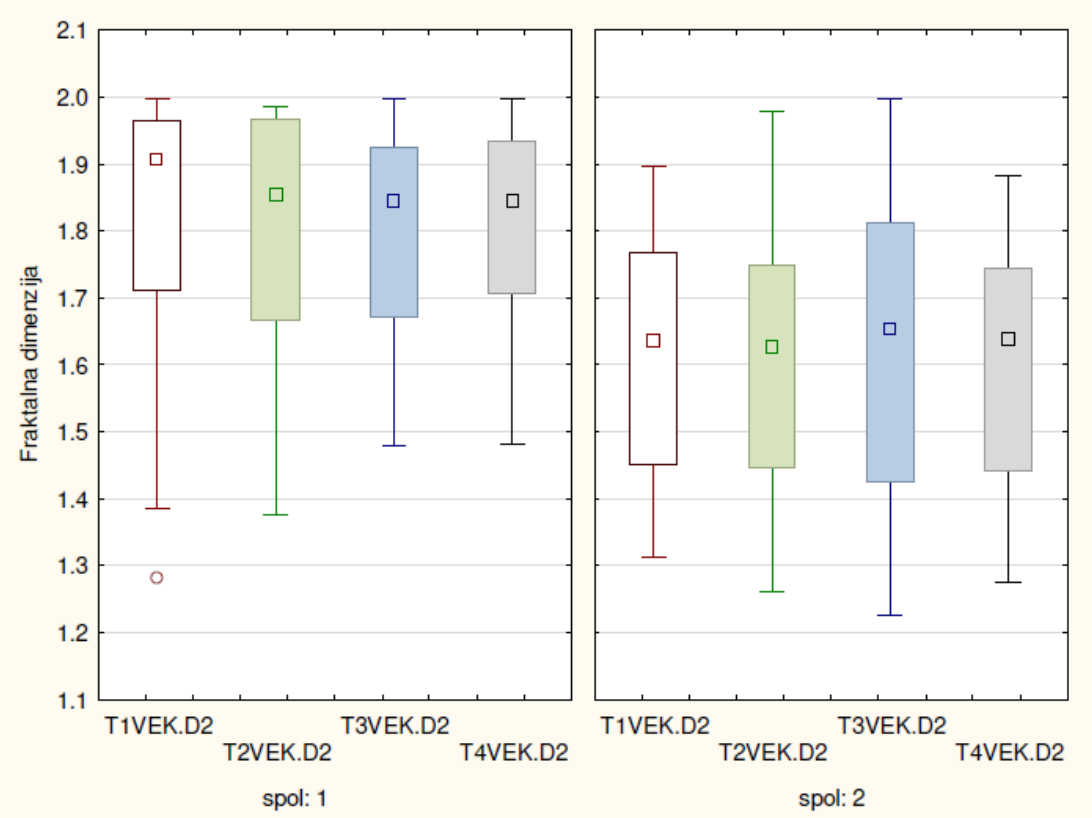
Slika 5.9. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike vrijednosti R/S fraktalne dimenzije centrifugalnog vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 i T2 – prva i druga četvrtina izlaganja, VEK2 – centrifugalni vektor, D1 – R/S izračun fraktalne dimenzije).

Iz grafikona na slici 5.9. možemo vidjeti da postoji razlika R/S fraktalne dimenzije centrifugalnog vektora ovisna o spolu tijekom prve dvije četvrtine izlaganja, pri čemu je u žena fraktalna vrijednost veća (spol 2).

Tablica 5.2. Prikaz razdioba vrijednosti fraktalne dimenzije *wavelet* transformacijom

Razdioba vrijednosti wavelet fraktalne dimenzije električne aktivnosti tijekom 4 faze opterećenja po spolu i treniranosti ispitanika		Načini mjerenja električne aktivnosti paralumbalne muskulature				
		Položaj mjerenja duž osi faznog prostora (mV)			Vektor faznog prostora (mV)	
					temporalni	centrifugalni
Pokazatelji (Kruskal-Wallis (p))		X (lijevo-desno)	Y (gore-dolje)	Z (naprijed-nazad)	od prethodnog mjerenja	od aritmetičkog centra oblaka
Razdioba po spolu (M ili Ž)	1. četvrtina	0,01	>0,05	>0,05	0,002	>0,05
	2. četvrtina	>0,05			0,007	
	3. četvrtina				0,007	
	4. četvrtina				<0,001	
Razdioba po utreniranosti (od 2 do 6)	1. četvrtina				>0,05	
	2. četvrtina					
	3. četvrtina					
	4. četvrtina					

Tablica 5.2. prikazuje razliku u fraktalnoj dimenziji razdiobom po spolu i stupnju utreniranosti paralumbalne muskulature kada je fraktalna dimenzija računata *wavelet* transformacijom. Tablica je zanimljiva zato što je računanje vrlo malo podataka dalo značajne rezultate. Postojale su samo dvije razlike i to osi X (pomak lijevo – desno) između spolova te razlika u temporalnom vektoru. Promatrajući temporalni vektor u sva četiri stupnja vidimo ključnu razliku: kada računamo fraktalne dimenzije *wavelet* transformacijom muškarci imaju veću fraktalnu dimenziju temporalnog vektora u odnosu na ženske ispitanike (pravokutni grafikon / raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti, na slici 5.10.).



Slika 5.10. Pravokutni grafikon (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Razlike vrijednosti *wavelet* fraktalne dimenzije temporalnog vektora, ovisno o spolu (spol 1 – muški spol, spol 2 – ženski spol, T1 – T4 – prva do čevrta četvrtina izlaganja, VEK – temporalni vektor, D2 – *wavelet* izračun fraktalne dimenzije).

5.2.2. RAZLIKE U FRAKTALNOJ DIMENZIJI IZMEĐU ISPITANIKA SVRSTANIH U EM KLASTERE PO TIPU UMARANJA

Ispitanici su metodom EM klastera razvrstani prema načinu promjene fraktalne dimenzije tijekom četiri faze izlaganja. Nakon toga su tako detektirani klasteri međusobno uspoređeni po spolnoj i dobnoj razdiobi, kao i po stupnju utreniranosti.

U izračunu su rabljeni ranije opisani zapisi pet načina mjerenja električne aktivnosti paralumblne muskulature. Posebno za svaki od pet načina mjerenja, izračun EM klastera temeljio se na vrijednosti fraktalne dimenzije tog načina mjerenja u prvoj, drugoj, trećoj i četvrtoj četvrtini opterećenja na vibrirajućoj platformi. Tako su grupirani ispitanici sa sličnim uzorkom promjene vrijednosti fraktalne dimenzije tijekom četiri faze izlaganja vibracijama. Rabljena je metoda autodetekcije broja postojećih klastera u određenom skupu podataka. Po definiranju razdiobe ispitanika po klasterima, razlike između klastera testirane su Kruskal-

Wallisovim testom kao neparametrijskom metodom izračuna značajnosti razlike između nezavisnih uzoraka.

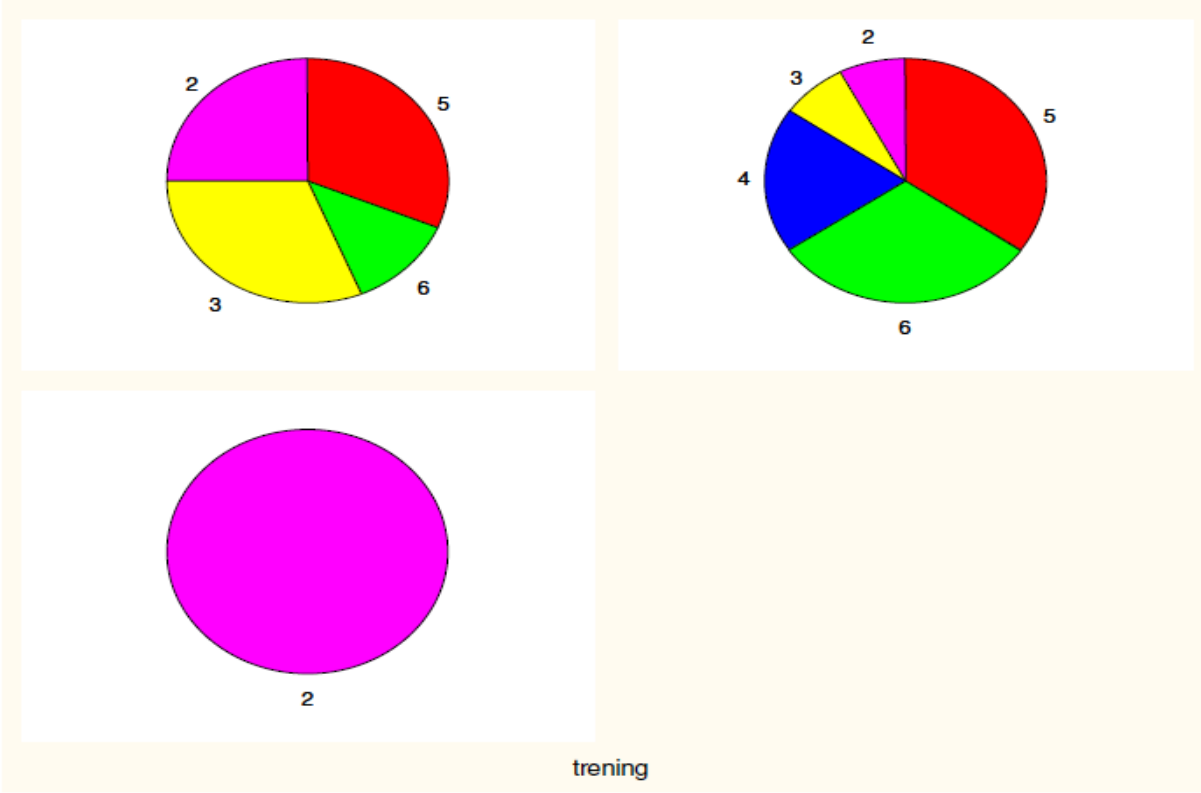
Rezultati za analizu podataka fraktalne dimenzije dobivene R/S analizom prikazani su u tablici 5.3.

Tablica 5.3. Razlike R/S fraktalne dimenzije između EM klastera ispitanika

EM klasteri ispitanika temeljem vrijednosti R/S fraktalne dimenzije električne aktivnosti tijekom 4 faze opterećenja		Načini mjerenja električne aktivnosti paralumbalne muskulature				
		Položaj mjerenja duž osi faznog prostora (mV)			Vektor faznog prostora (mV)	
					temporalni	centrifugalni
		X (lijevo-desno)	Y (gore-dolje)	Z (naprijed-nazad)	od prethodnog mjerenja	od aritmetičkog centra oblaka
Broj nađenih EM klastera tipova električne aktivnosti		2	3	3	3	2
Pokazatelji		Razdioba vrijednosti pokazatelja po EM klasterima električne aktivnosti (Kruskal-Wallis (p))				
spol		>0,05	>0,05	0,004	0,02	<0,001
dob		>0,05	0,03	>0,05	>0,05	>0,05
utreniranost		>0,05	0,01	>0,05	>0,05	>0,05
Fraktalna dimenzija električne aktivnosti tijekom faza opterećenja	1. četvrtina	>0,05	<0,001	<0,001	0,002	<0,001
	2. četvrtina	>0,05	<0,001	<0,001	<0,001	<0,001
	3. četvrtina	>0,05	<0,001	<0,001	<0,001	<0,001
	4. četvrtina	>0,05	<0,001	<0,001	<0,001	<0,001

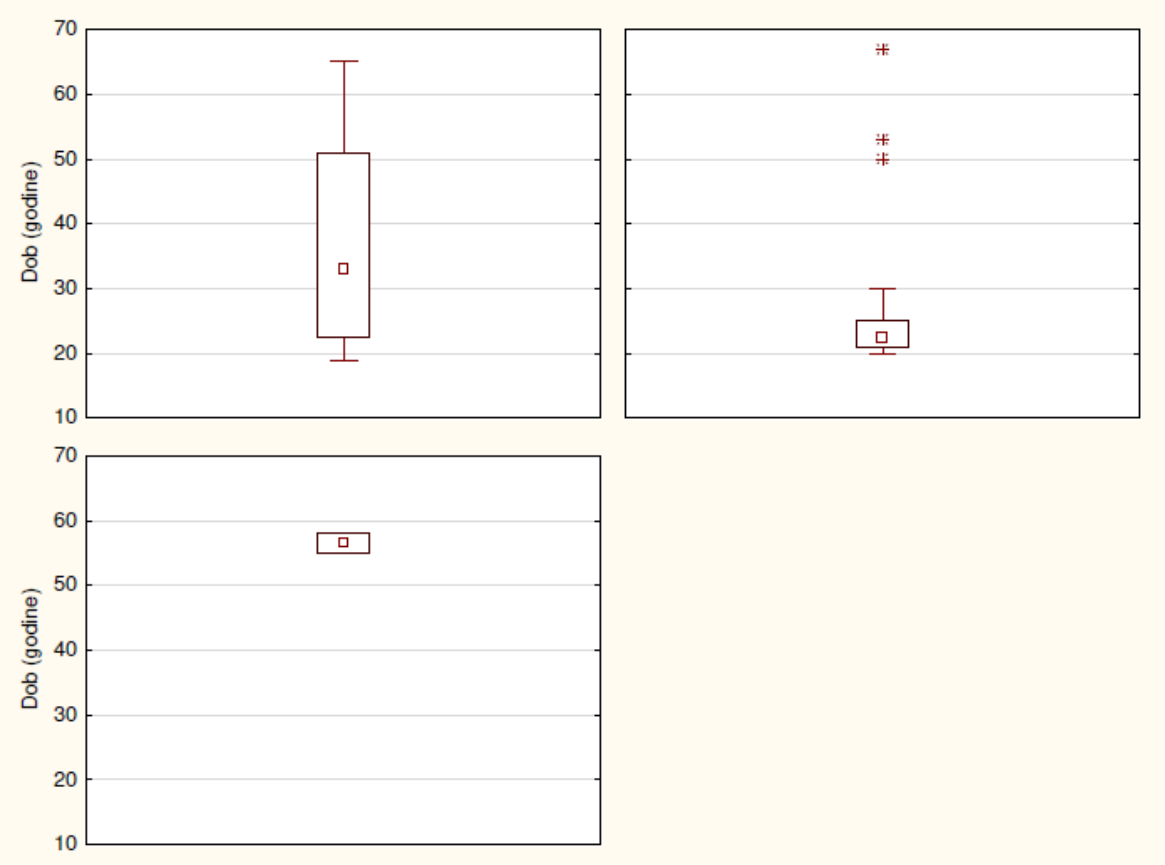
Metodom autodetekcije broja klastera utvrđeno je tako da postoje dva klastera za položaj duž osi X, tri za položaj duž osi Y, tri za položaj duž osi Z, tri za centrifugalni i dva klastera za temporalni vektor. Prvo je testiran spol, zbog bitnih anatomskih razlika između muškaraca i žena u području paralumbalne muskulature, zdjelice, načina stajanja pa samim time i očekivanih razlika po pitanju aktivacije muskulature na vibrirajućoj platformi. Drugi testirani pokazatelj bila je dob, jer se očekuje da je utreniranost i snaga muskulature kao i osjetljivost senzora ravnoteže i drugih bitnih komponenata aktivacije paralumbalne muskulature na vibrirajućoj platformi povezana upravo s dobi. Treći testirani pokazatelj bila je semikvalitativna procjena utreniranosti u vrijednostima na ljestvici od 2 do 6, pri čemu je 2 vrlo mala utreniranost, a 6 je utreniranost osoba koje redovito duže od 6 mjeseci treniraju ples. Također su Kruskal-Wallisovim testom testirane razlike između vrijednosti fraktala u

klasterima za sve četiri faze izlaganja vibracijama. Iz tablice 5.3. razvidno je da nisu pronađene značajne razlike između dva klastera u podacima o pomaku duž osi X (lijevo – desno). Što se tiče pomicanja duž osi Y (gore – dolje), značajno je da nisu uočene razlike po spolu te je u sva tri klastera razdioba po spolu bila slična. No, uočena je bitna razlika ispitanika po dobi unutar tih klastera, kao i po stupnju utreniranosti. Tu je nađena i vrlo značajna razlika u vrijednostima R/S fraktalne dimenzije duž osi Y. Što se tiče položaja duž osi Z, naprijed – nazad, uočena je značajna razlika među spolovima što se može shvatiti razlikama u građi zdjelice, snazi muskulature te položaju cijeloga tijela s obzirom na anatomske razlike pa samim time i promjenom kretanja električnog polja u smjeru naprijed – nazad tijekom opterećenja na vibrirajućoj platformi dok po pitanju dobi i utreniranosti nisu nađene značajne razlike. Slično tome, za temporalni i za centrifugalni vektor nađene su značajne razlike u spolnoj razdiobi, a nisu nađene u razdiobi stupnja utreniranosti i razdiobi dobi ispitanika. Na temelju tih rezultata u tablici 5.3. detaljnije su analizirane uočene razlike u klasterima nađenima za položaj električnog polja u smjeru osi Y, za smjer Z i za oba vektora.



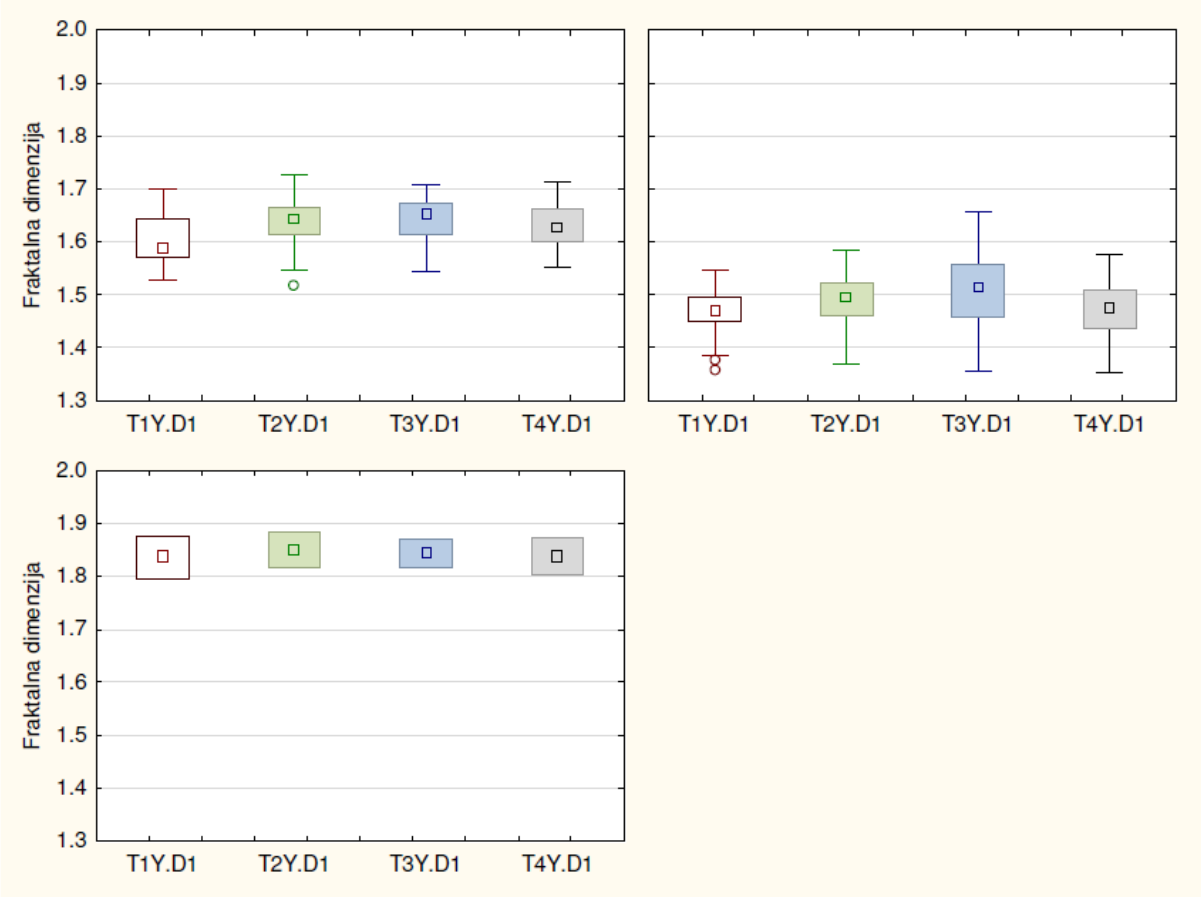
Slika 5.11. Prikaz razdiobe stupnja utreniranosti ispitanika u tri klastera ispitanika po mijeni R/S fraktalne dimenzije gibanja po osi Y (trening – stupanj utreniranosti od 2 do 6)

Što se tiče smjera osi Y grafikon na slici 5.11. pokazuje razdiobu stupnja utreniranosti iz čega je razvidno da je najmanja utreniranost bila u klasteru 3, najbolja u klasteru 2, a srednja utreniranost u klasteru 1.



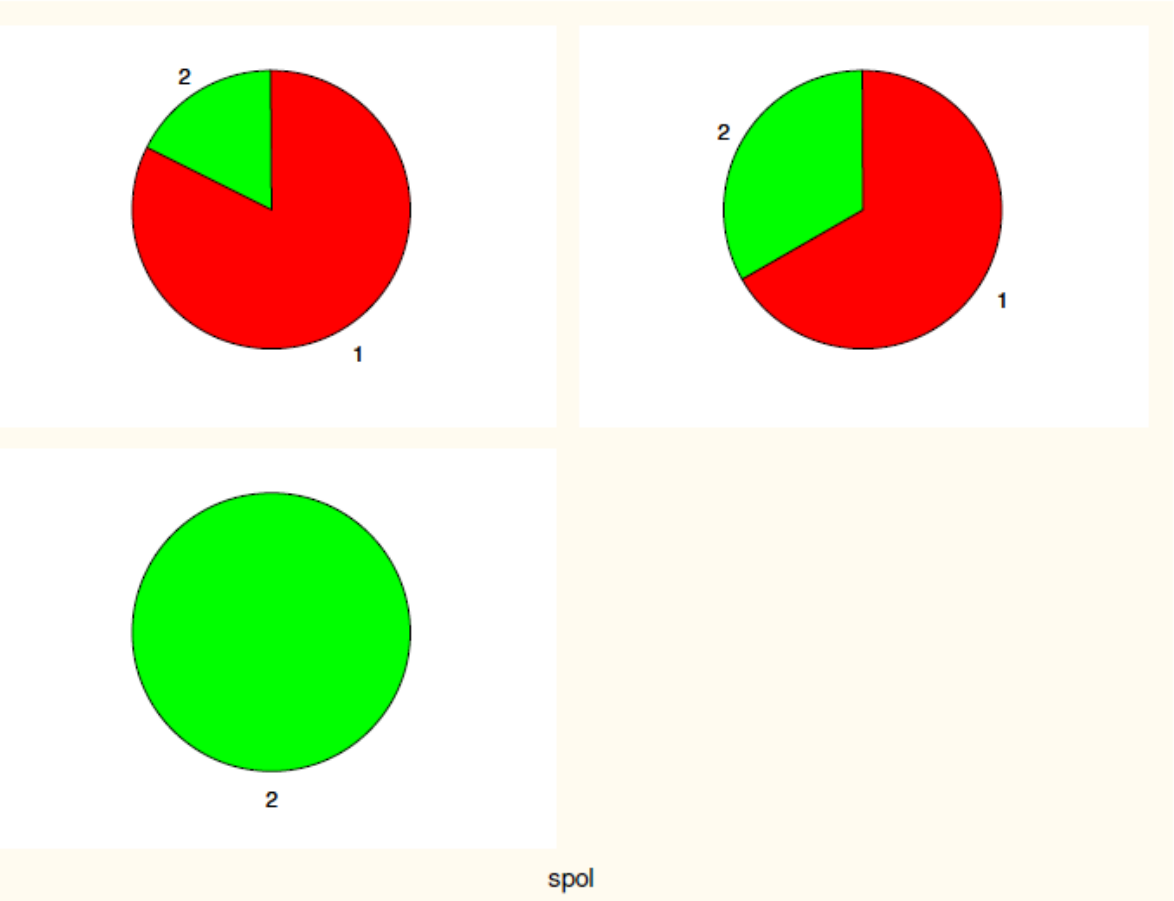
Slika 5.12. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe dobi ispitanika u tri klastera ispitanika po mijeni R/S fraktalne dimenzije gibanja po osi Y.

U grafikonu na slici 5.12. vidimo značajnu razliku u dobi, koja je normalno povezana sa specifičnom dobnom strukturom naših ispitanika i zapravo odražava razdiobu utreniranosti iz grafikona na slici 5.11.



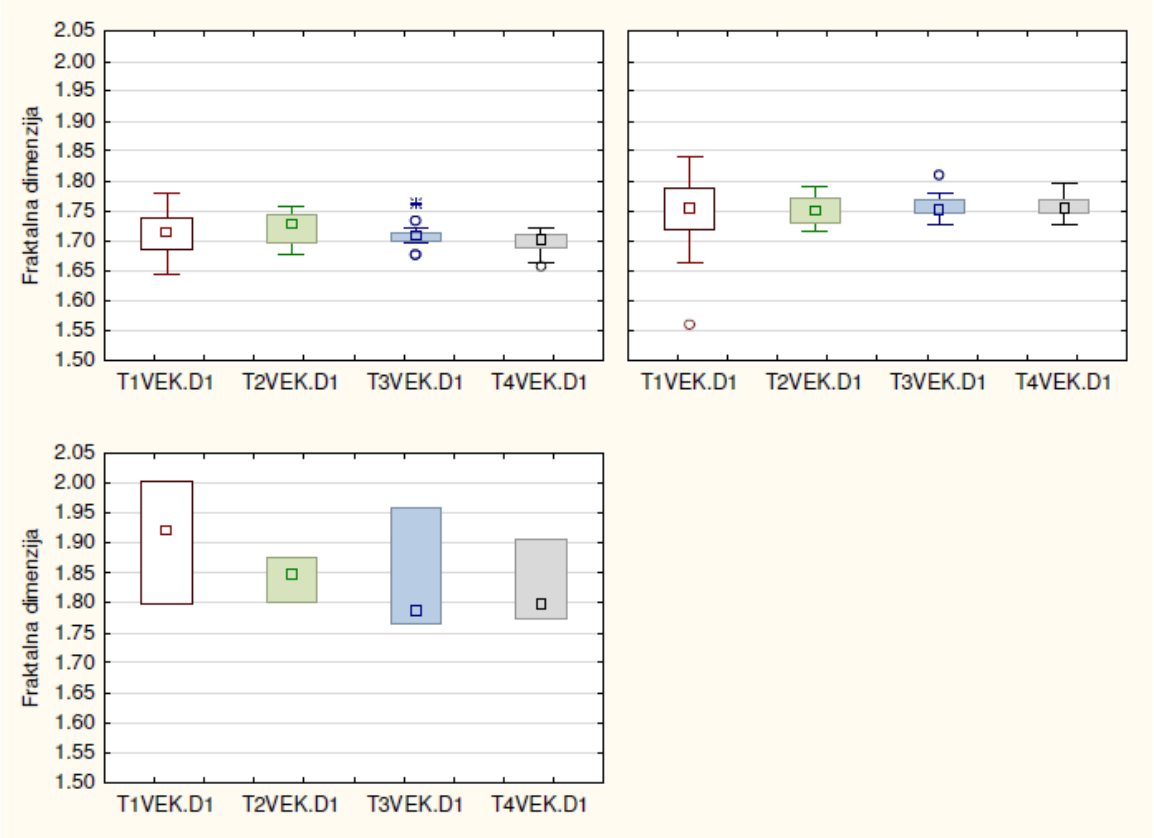
Slika 5.13. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz tipa promjene R/S fraktalne dimenzije gibanja po osi Y tijekom četiri faze izlaganja vibracijama (T1 – T4 – prva do četvrta četvrtina izlaganja, Y – os faznog prostora, D1 – R/S izračun fraktalne dimenzije).

U grafikonu na slici 5.13. možemo vidjeti da je najutreniraniji klaster ispitanika klaster 2 imao početno najniže R/S vrijednosti fraktalne dimenzije koje su tijekom izlaganja pokazale umjeren porast. Najviši medijan uočen je u trećoj četvrtini opterećenja, da bi u četvrtoj četvrtini došlo do povratka na početne vrijednosti, pa i malo niže od toga. Najslabije utrenirani klaster broj 3 imao je značajno više vrijednosti fraktalne dimenzije, a srednje utrenirani klaster broj 1 pokazao je srednje visoke vrijednosti fraktalnih dimenzija koje su po dinamici tijekom vremena bile slične klasteru broj 2.



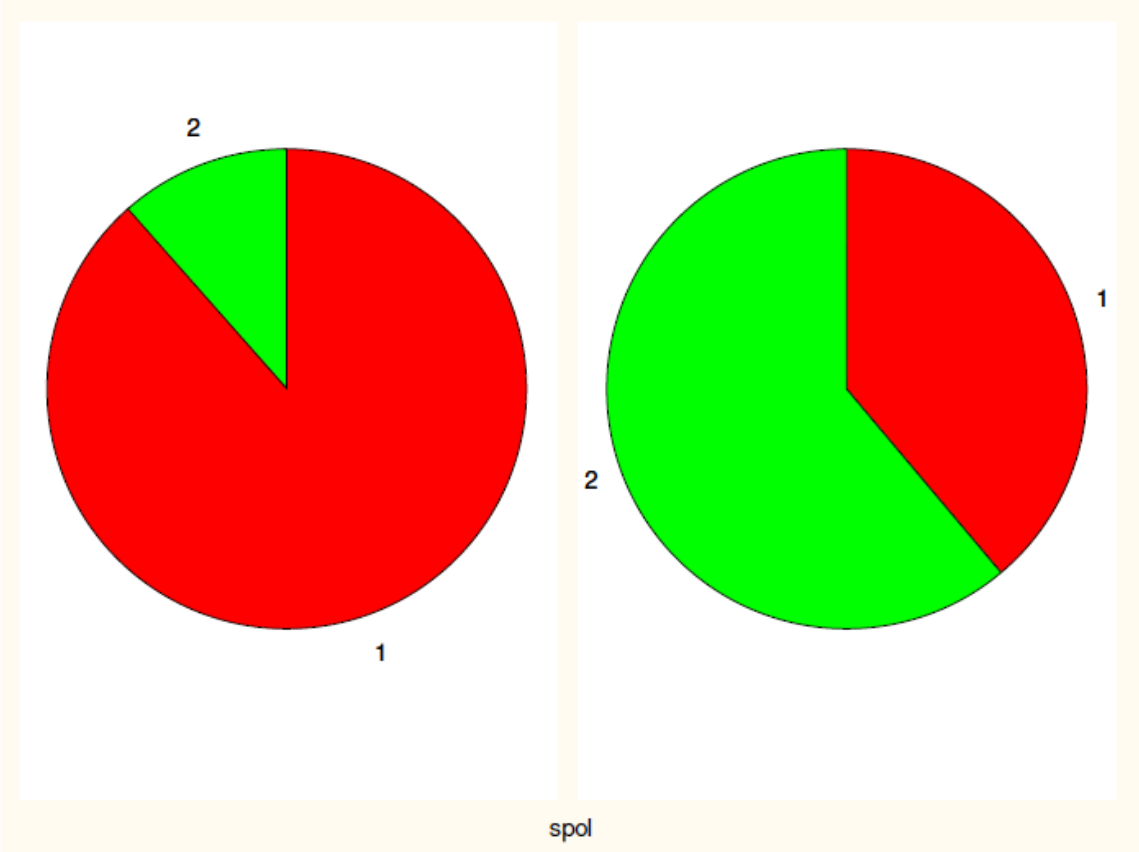
Slika 5.14. Prikaz razdiobe po spolu u tri klastera ispitanika po mijeni R/S fraktalne dimenzije temporalnog vektora (1 – muški spol, 2 – ženski spol)

U grafikonu na slici 5.14. vidimo spolnu strukturu klastera dobivenih iz vrijednosti fraktalnih dimenzija temporalnog vektora pri čemu se vidi da je klaster 1 dominantno muškoga spola, klaster 3 su isključivo žene, a klaster 2 je između te dvije vrijednosti.



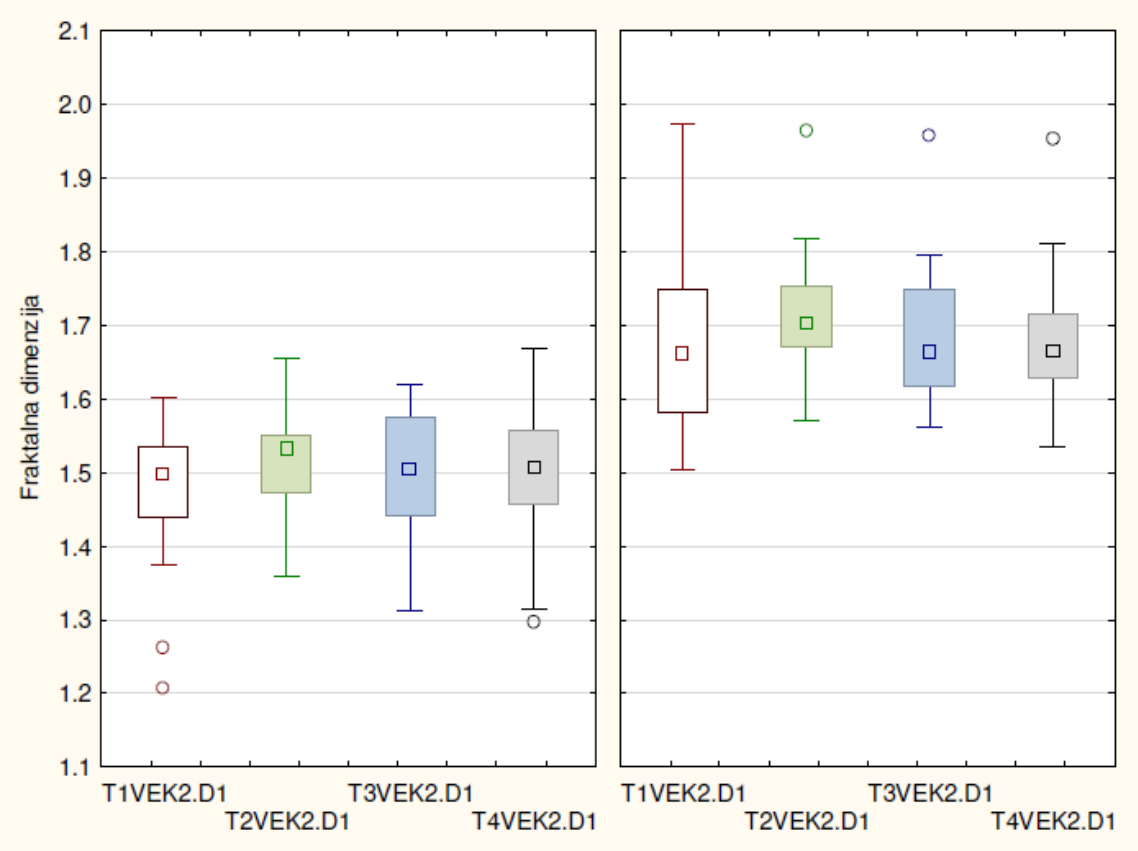
Slika 5.15. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u tri klastera ispitanika po mijeni fraktalne dimenzije temporalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK – temporalni vektor, D1 – R/S izračun fraktalne dimenzije).

U grafikonu na slici 5.15. možemo vidjeti da ispitanici u većinom muškom prvom klasteru imaju najniže vrijednosti R/S fraktalne dimenzije koje se nisu bitno mijenjale tijekom napora s time da su najviše porasle u drugoj četvrtini opterećenja da bi se u trećoj i četvrtoj četvrtini spustile na početne vrijednosti. Treći klaster, koji su činile žene, imao je značajno više vrijednosti R/S fraktalnih dimenzija i uz opterećenje je umjesto porasta došlo do pada fraktalne dimenzije pa se najniža vrijednost vidi u trećoj četvrtini opterećenja uz neznatan oporavak na samome kraju opterećenja. Klaster broj dva, koji je bio miješane spolne strukture, između ranije opisana dva više je nalikovao na muški klaster što odgovara i omjeru spolova vidljivom u ranijem grafikonu na slici 5.14.



Slika 5.16. Prikaz razdiobe po spolu u dva klastera ispitanika po mijeni R/S fraktalne dimenzije centrifugalnog vektora (1 – muški spol, 2 – ženski spol)

Grafikon na slici 5.16. pokazuje spolnu strukturu klastera dobivenih analizom centrifugalnih vektora metodom R/S algoritma pri čemu je razvidno da su prvim klasterom dominirali muškarci, a drugim žene.



Slika 5.17. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u dva klastera ispitanika po mijeni fraktalne dimenzije centrifugalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK2 – centrifugalni vektor, D1 – R/S izračun fraktalne dimenzije).

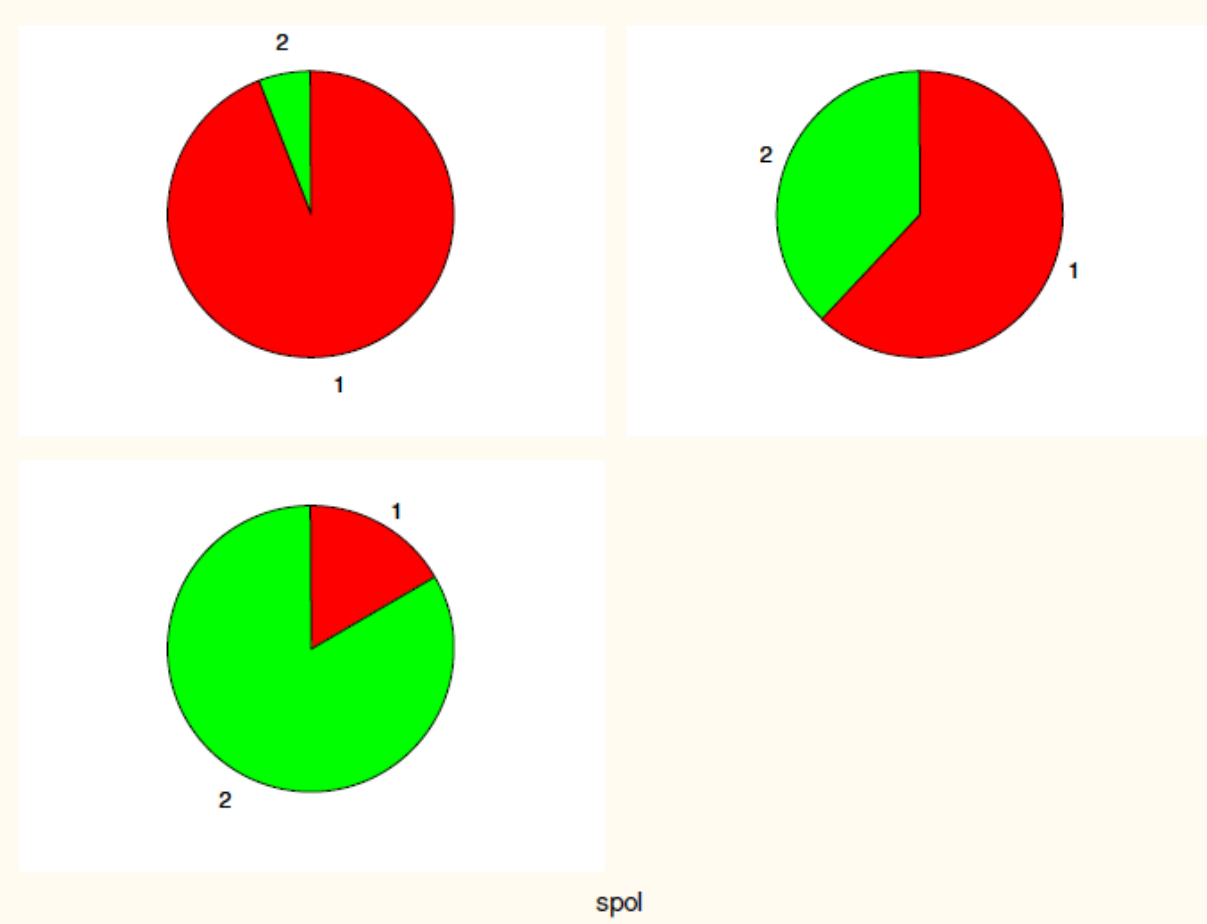
Što se tiče promjene fraktalne dimenzije tijekom opterećenja, iz grafikona na slici 5.17. vidljivo je da su žene u drugom klasteru imale značajno veće vrijednosti R/S fraktalnih dimenzija, ali su i jedan i drugi klaster na opterećenje reagirali povećanjem fraktalnosti centrifugalnih vektora u drugoj četvrtini opterećenja da bi kasnije došlo do oporavka, slično kao i u temporalnom vektoru.

5.2.3. FRAKTALNE DIMENZIJE RAČUNATE *WAVELET* TRANSFORMACIJOM IZMEĐU EM KLASTERA ISPITANIKA

Tablica 5.4. Razlike fraktalne dimenzije računate *wavelet* transformacijom između EM klastera ispitanika

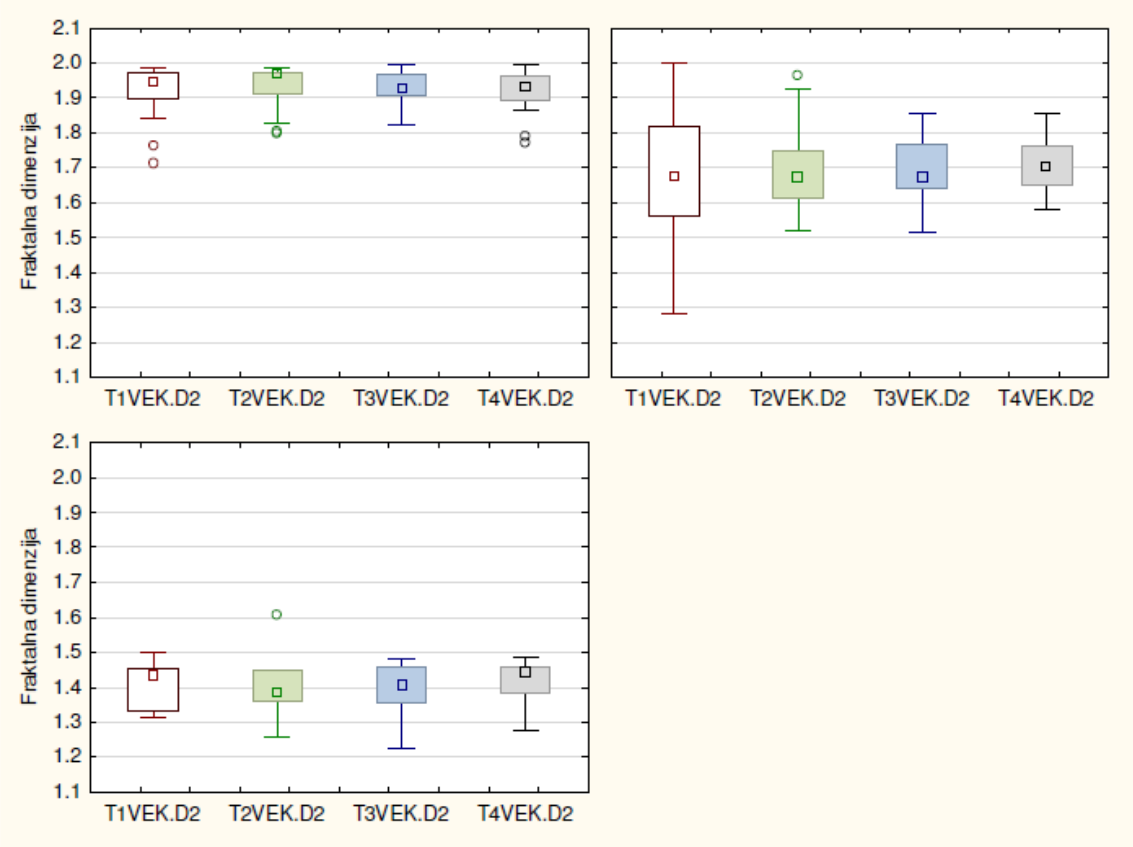
EM klasteri ispitanika temeljem vrijednosti wavelet fraktalne dimenzije električne aktivnosti tijekom 4 faze opterećenja		Načini mjerenja električne aktivnosti paralumbalne muskulature				
		Položaj mjerenja duž osi faznog prostora (mV)			Vektor faznog prostora (mV)	
					temporalni	centrifugalni
		X (lijevo-desno)	Y (gore-dolje)	Z (naprijed-nazad)	od prethodnog mjerenja	od aritmetičkog centra oblaka
Broj nađenih EM klastera tipova električne aktivnosti		2	3	5	3	2
Pokazatelji		Razdioba vrijednosti pokazatelja po EM klasterima električne aktivnosti (Kruskal-Wallis (p))				
spol		>0,05	>0,05	>0,05	0,002	>0,05
dob					>0,05	
utreniranost						
Fraktalna dimenzija električne aktivnosti tijekom faza opterećenja	1. četvrtina	<0,001	<0,001	<0,001	<0,001	<0,001
	2. četvrtina					
	3. četvrtina					
	4. četvrtina					

U tablici 5.4. vidimo da je na jednak način učinjena analiza podataka fraktalne dimenzije izračunata *wavelet* transformacijom. Važno je istaknuti da je od pet definiranih načina mjerenja značajnost po spolu, dobi i utreniranosti nađena samo za temporalni vektor i to po spolu.



Slika 5.18. Prikaz razdiobe po spolu u tri klastera ispitanika po mijeni *wavelet* fraktalne dimenzije temporalnog vektora (1 – muški spol, 2 – ženski spol)

Iz toga je razloga grafički prikazana samo razdioba s temporalnim vektorom. Grafikonom na slici 5.18. prikazana su tri klastera od kojih je prvi dominantno muški, treći dominantno ženski, dok je drugi miješane spolne strukture.



Slika 5.19. Pravokutni grafikoni (raspon 25 – 75 % s prikazom medijana i ekstremnih vrijednosti). Prikaz razdiobe *wavelet* fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u tri klastera ispitanika po mijeni fraktalne dimenzije temporalnog vektora (T1 – T4 – prva do četvrta četvrtina izlaganja, VEK – temporalni vektor, D2 – *wavelet* izračun fraktalne dimenzije).

Iz grafikona na slici 5.19. vidljivo je da ako računamo fraktalnu dimenziju podataka temporalnog vektora *wavelet* algoritmom, ona je u klasteru u kojemu dominiraju žene (klaster 3) niža u odnosu na klaster kojim dominiraju muškarci (klaster 1). U mješovitom klasteru 2 njezina je vrijednost između. Također se može primijetiti da je odgovor na opterećenje različit, pa tako u klasteru u kojem dominiraju žene (klaster 3) u drugoj četvrtini medijan razdiobe opada, a u muškaraca (klaster 1) blago raste. Izračun *wavelet* transformacijom u slučaju temporalnog vektora pokazao je bitno drukčiju razdiobu ovisno o spolu i to na način da ženama pridružuje niže vrijednosti u odnosu na R/S algoritam.

6. RASPRAVA

6.1. ZNAČAJKE VIZUALIZACIJE PROMJENE ELEKTRIČNE AKTIVNOSTI PARALUMBALNE MUSKULATURE TIJEKOM NAPORA

Kao što je ranije u rezultatima prikazano slikama (slike 5.1. do 5.4.), električna aktivnost paralumbalne muskulature snimana je kod više mladih muških ispitanika. Tri para kutanih elektroda tako su postavljena duž tri prostorne osi da je u njihovu centru bila paralumbalna muskulatura. Ispitanici su zauzimali tjelesni položaj u kojemu je potaknuta kontraktilna aktivnost paralumbalne muskulature kao odgovor na vibraciju cijeloga tijela. Za svakog ispitanika, tijekom 200 sekundi prikupljeno je 200 000 pozicija električnog polja u faznom prostoru u kojemu je položaj pojedine točke definiran koordinatama izraženim u milivoltima (mV). Točke su podijeljene vremenski u 4 faze po 50 sekundi i dodatno su prikazane u tri sloja promatrajući električnu aktivnost paralumbalne muskulature u frontalnim ravninama koje prolaze kroz dorzalni, srednji i ventralni prostor mjernog volumena. Električna aktivnost paralumbalne muskulature svakoga ispitanika, nakon tako obrađenog zapisa, u konačnici je prikazana kao niz od 12 malih oblaka podataka, kao na slikama 5.1. do 5.4., pri čemu tri reda sličica predstavljaju slojeve prostora, a stupci sličica su faze u vremenu (prvih, drugih, trećih i četvrtih 50 sekundi). Iz slika je razvidno da postoje značajne promjene u obliku i gustoći oblaka točaka, i po sloju faznog prostora, i tijekom napora. Evidentno je da tijekom napora dolazi do pojave asimetrije oblaka podataka, koje se ponekad u zadnjem dijelu napora donekle umanje. Navedena pilot mjerenja jasno su ukazala da bi ova metoda mogla biti korisna za praćenje rada mišića tijekom vježbe, no ostalo je razviti statističke ili matematičke metode kojima bi se vizualna informacija iz opisanih slika mogla prikladno numerički iskazati i poslužiti kao jasan pokazatelj zbivanja. Primjena modificiranog oblika površinske elektromiografije i u našem radu pokazala se kao najbolja metoda za kontinuirano praćenje lokalnog umora mišića, odnosno ponašanja mišića za vrijeme opterećenja što samo ide u prilog njezinoj ranijoj primjeni i ocjeni od strane drugih autora osobito u svom preciznom bilježenju promjena u mioelektričnom signalu iznad površine kože promatranoga mišića ili mišićne skupine (60 - 65). Istraživanje se temeljilo na našim iskustvima snimanja trodimenzijskog elektrokardiograma visoke rezolucije uporabom digitalnog mjernog uređaja Biopac Student Lab kao pouzdanog i lako prilagodljivog mjernog instrumenta električne aktivnosti čiji su rezultati suglasni s navodima drugih autora nastalima pri promatranju srčanog mišića (66, 81).

6.2. ZNAČAJKE FRAKTALNOSTI ELEKTRIČNE AKTIVNOSTI PARALUMBLANE MUSKULATURE TIJEKOM NAPORA

Istraživanje prikupljenih podatka provedeno je upotrebom više različitih metoda. Iz sirovih podataka električne aktivnosti paralumbalne muskulature tijekom 200 s izlaganja vibracijama prvo su uklonjeni QRS kompleksi srčane aktivnosti, a zatim je po četvrtinama trajanja (50 s) izdvojeno po pet posebnih zapisa za daljnju analizu (zapis osi X, Y, Z, zapis temporalnog i centrifugalnog vektora). Po jednom ispitaniku tako je nastalo 20 zapisa (četiri četvrtine od kojih svaka ima pet zapisa). Za svaki zapis izračunata je fraktalna dimenzija po metodi R/S analize i *wavelet* transformacije, pa je svaki ispitanik dobio dvije različite vrijednosti fraktalne dimenzije za svaki od 20 zapisa. Vrijednosti fraktalne dimenzije u kasnijim su analizama rabljene kao brojčani pokazatelj složenosti variranja izmjerenih električnih vrijednosti u pojedinom zapisu. Primjena koncepta fraktala kroz izračun R/S algoritma i *wavelet* transformacije temeljen je na iskustvima autora koji su analizirali složene fluktuacije pokazatelja tijekom različitih vremenskih perioda (66, 79). U prvom dijelu analize izračunatih fraktalnih dimenzija bilo nam je važno utvrditi postoji li razlika u R/S fraktalnim dimenzijama ovisno o spolu i utreniranosti paralumbalne muskulature (tablica 5.1.) te je uočeno da je razdioba po spolu postojala i to u smjeru X (lijevo – desno) samo za mjerenje u prvoj i drugoj četvrtini snimanja. Po smjeru Y (gore – dolje) nije postojala razlika po spolu. Po smjeru Z (naprijed – nazad) uočena je razlika po spolu što najvjerojatnije ide u prilog anatomskim razlikama u građi zdjelice i različitoj jačini muskulature. Promatrajući vektore, vidljivo je da se temporalni vektor (brzina promjene električnog polja) u sve četiri faze mjerenja značajno razlikuje po spolu, dok se centrifugalni (udaljenosti od središta oblaka podataka u faznom prostoru) razlikovao samo u prve dvije četvrtine vremena. Promatrajući razdiobu po stupnju utreniranosti, jedine tri značajne razlike uočene su u smjeru Y (gore – dolje) u prve dvije četvrtine te u temporalnom vektoru tijekom treće četvrtine. Daljnjim promatranjem razdiobe vrijednosti R/S fraktalne dimenzije po osi X u prvome i drugome vremenu ovisno o spolu (slika 5.5.) možemo vidjeti da je fraktalna dimenzija u muškaraca u prvoj četvrtini bila razmjerno niska i širokoga raspona, da bi zagrijavanjem, tijekom druge četvrtine izlaganja vibracijama došlo do porasta fraktalne dimenzije i suženja raspona vrijednosti. Kod ispitanica došlo je do obrnute situacije, početna vrijednost je bila viša nego u muškaraca i razmjerno uskoga raspona. Međutim, daljnjim izlaganjem naporu došlo je do sniženja medijana fraktalne dimenzije i proširenja raspona. Nadalje, promatranjem stupnja utreniranosti kroz R/S

fraktalnu dimenziju električne aktivnosti (slika 5.6.), u smjeru osi Y (gore – dolje), u prvoj i drugoj četvrtini vremena izlaganja, razvidno je da najslabije utrenirani ispitanici (stupanj utreniranosti 2), imaju razmjerno visoke vrijednosti fraktalne dimenzije koje se krajem izlaganja još povećavaju, dok ispitanici koji su visoko utrenirani (stupanj utreniranosti 5 i 6), imaju niske vrijednosti mnogo užega raspona tijekom izlaganja te se raspon vrijednosti fraktalne dimenzije donekle proširuje u drugoj četvrtini izlaganja. Ispitanici trećega stupnja utreniranosti ponašaju se dosta slično neutreniranima, a ispitanici četvrtoga stupnja utreniranosti slični su dobro utreniranim ispitanicima što je u suglasju s našom procjenom njihove utreniranosti. Analizirajući razlike u R/S fraktalnih dimenzija, ovisnih o spolu (slika 5.7.), a u smjeru osi Z (naprijed – nazad) tijekom četiri faze izlaganja, mogli smo vidjeti da se u muških ispitanika razmjerno niska fraktalna dimenzija tijekom napora povisuje i to u drugoj četvrtini opterećenja, da bi se kasnije lagano snižavala i u četvrtoj četvrtini postala vrlo slična početnoj. Bitno drukčiju situaciju imali smo u ispitanica, gdje je fraktalna dimenzija bila visoka i širokoga raspona u prvoj četvrtini, a kasnije se postupno snižava i sužava tijekom izlaganja naporu, s time da su R/S vrijednosti fraktalnih dimenzija kroz sve četiri četvrtine bitno više nego kod muškaraca. Također smo, ovisno o spolu, promatrali razlike u fraktalnoj dimenziji temporalnog vektora (slika 5.8.). U muškaraca opterćenjem dolazi do suženja rasapa vrijednosti fraktalne dimenzije oko gotovo nepromijenjenog medijana da bi u zadnjoj četvrtini rasap vrijednosti postao sličan rasapu u prvoj četvrtini. Kod ispitanica su vrijednosti fraktalne dimenzije u prvoj četvrtini više nego u muškaraca i nastavkom opterećenja pokazuju umanjeni medijan i umanjeni rasap, bez povratka na situaciju u prvoj četvrtini. Moguća interpretacija je da su muškarci pokazali umjereno umaranje i oporavak dok je kod ispitanica utvrđen uzorak umaranja bez oporavka. Promatrajući razlike vrijednosti R/S fraktalne dimenzije centrifugalnog vektora ovisnog o spolu (slika 5.9.) zapazili smo da je postojala razlika R/S fraktalne dimenzije centrifugalnog vektora ovisna o spolu tijekom prve dvije četvrtine izlaganja, pri čemu je kod žena fraktalna vrijednost veća te je oblak podataka R/S fraktalne dimenzije u žena bio većih dimenzija u faznom prostoru. Jednako smo analizirali vrijednosti fraktalne dimenzije dobivene *wavelet* transformacijom (tablica 5.2.). Računanjem fraktalne dimenzije za sve tri osi i dva vektora, a razdiobom po spolu i stupnju utreniranosti dobili smo vrlo malo značajnih rezultata. Uočene su samo dvije razlike. Prva vezana za osi X (pomak lijevo – desno) između spolova te razlika u temporalnom vektoru. Promatrajući temporalni vektor u sva četiri stupnja uočavamo ključnu razliku: kada računamo fraktalne

dimenzije *wavelet* transformacijom, muškarci imaju veću fraktalnu dimenziju temporalnog vektora u odnosu na ispitanice.

6.3. ZNAČAJKE RAZLIKA FRAKTALNE DIMENZIJE IZMEĐU ISPITANIKA SVRSTANIH U EM KLASTERE PO TIPU UMARANJA

Budući da je polazna postavka istraživanja kako definirati umaranje paralumbalne muskulature tijekom izlaganja vibracijama, i kao što je vidljivo iz tablice 5.3., ispitanici su metodom EM klastera razvrstani prema načinu promjene fraktalne dimenzije tijekom četiri faze izlaganja. Nakon toga su tako detektirani klasteri međusobno uspoređeni po spolnoj i dobnoj razdiobi, kao i po stupnju utreniranosti. U izračunu su rabljeni ranije opisani zapisi pet načina mjerenja električne aktivnosti paralumbalne muskulature. Posebno za svaki od pet načina mjerenja, izračun EM klastera temeljio se na vrijednosti fraktalne dimenzije tog načina mjerenja u prvoj, drugoj, trećoj i četvrtoj četvrtini opterećenja na vibrirajućoj platformi. Tako su grupirani ispitanici sa sličnim uzorkom promjene vrijednosti fraktalne dimenzije tijekom četiri faze izlaganja vibracijama. Rabljena je metoda autodetekcije broja postojećih klastera u određenom skupu podataka. Po definiranju razdiobe ispitanika po klasterima, razlike između klastera testirane su Kruskal-Wallisovim testom kao neparametrijskom metodom izračuna značajnosti razlike između nezavisnih uzoraka. Metodom autodetekcije broja klastera tako je utvrđeno da su postojala dva klastera za položaj duž osi X, tri za položaj duž osi Y, tri za položaj duž osi Z, tri za centrifugalni i dva klastera za temporalni vektor. Prvo je testiran spol, zbog bitnih anatomskih razlika između muškaraca i žena u području paralumbalne muskulature, zdjelice, načina stajanja pa samim time i očekivanih razlika po pitanju aktivacije muskulature na vibrirajućoj platformi. Drugi testirani pokazatelj bila je dob, jer se očekuje da je utreniranost i snaga muskulature kao i osjetljivost senzora ravnoteže i drugih bitnih komponenata aktivacije paralumbalne muskulature na vibrirajućoj platformi povezana s dobi. Treći testirani pokazatelj bila je semikvalitativna procjena utreniranosti u vrijednostima na ljestvici od 2 do 6, pri čemu je 2 vrlo mala utreniranost, a 6 je utreniranost osoba koje redovito duže od 6 mjeseci treniraju ples. Također su Kruskal-Wallisovim testom testirane razlike između vrijednosti fraktala u klasterima za sve četiri faze izlaganja vibracijama. Promatranjem R/S fraktalne dimenzije razvidno je da nisu nađene značajne razlike između dva klastera u podacima o pomaku duž osi X (lijevo – desno), što se može smatrati očekivanim rezultatom jer je način opterećenja na vibrirajućoj platformi takve naravi da se ne

očekuje bitna aktivacija muskulature u smjeru lijevo – desno kod zdravih ispitanika sa simetričnom funkcijom paralumbalne muskulature. Ne može se isključiti mogućnost da bi slična istraživanja kod osoba s tegobama u lumbalnoj muskulaturi mogla pokazati značaj mjerenja duž osi X za detekciju patoloških promjena. Analizom pomicanja duž osi Y (gore – dolje), značajno je da nisu uočene razlike po spolu te je u sva tri klastera razdioba po spolu bila slična. No, zapažena je bitna razlika ispitanika po dobi unutar tih klastera, kao i po stupnju utreniranosti. Tu je uočena i vrlo značajna razlika u vrijednostima R/S fraktalne dimenzije duž osi Y. Što se tiče položaja duž osi Z, naprijed – nazad, uočena je značajna razlika među spolovima što se može shvatiti razlikama u građi zdjelice, snazi muskulature te položaju cijeloga tijela s obzirom na anatomske razlike pa samim time i promjenom kretanja električnog polja u smjeru naprijed – nazad tijekom opterećenja na vibrirajućoj platformi dok po pitanju dobi i utreniranosti nisu nađene značajne razlike. Slično tome, za temporalni i za centrifugalni vektor nađene su značajne razlike u spolnoj razdiobi, a nisu nađene u razdiobi stupnja utreniranosti i razdiobi dobi ispitanika. Nadalje, detaljnije su analize pokazale razlike u klasterima za položaj električnog polja u smjeru osi Y, za smjer Z i za oba vektora. Za smjer osi Y, a razdiobom po stupnju utreniranosti (slika 5.11.), vidljivo je da je najmanja utreniranost bila u klasteru 3, najbolja u klasteru 2, a srednja utreniranost u klasteru 1. Značajnu razliku u dobi (slika 5.12.), a koja je normalno bila povezana sa specifičnom dobnom strukturom naših ispitanika i koja zapravo odražava razdiobu utreniranosti (slika 5.11.), primijetili smo razdiobom dobi ispitanika u tri klastera po mjerenju R/S gibanjem po osi Y. Analizom tipa promjene R/S fraktalne dimenzije gibanjem po osi Y tijekom četiri faze izlaganja vibracijama (slika 5.13.) primijetili smo da je najutreniraniji klaster ispitanika bio klaster 2, koji je imao početno najniže R/S vrijednosti fraktalne dimenzije, a koje su tijekom izlaganja pokazale umjeren porast i najviši medijan koji je uočen u trećoj četvrtini opterećenja, da bi u četvrtoj četvrtini došlo do povratka na početne vrijednosti, pa i malo niže od toga. Najslabije utrenirani klaster broj 3 imao je značajno više vrijednosti fraktalne dimenzije, a srednje utrenirani klaster broj 1 pokazao je srednje visoke vrijednosti fraktalnih dimenzija koje su po dinamici tijekom vremena bile slične klasteru broj 2. Iz navedenoga se može zaključiti da je fraktalnost kretanja električnog polja duž osi Y u naših ispitanika pokazala konzistentne značajke povezane s utreniranošću ispitanika pri čemu je bolja utreniranost bila povezana s nižom fraktalnom dimenzijom izračunatom po R/S algoritmu. Razdioba ispitanika po spolu (slika 5.14.), u tri klastera po načinu promjene R/S fraktalne dimenzije temporalnog vektora pokazala je spolnu strukturu pri čemu smo vidjeli da je klaster

1 dominantno muškoga spola, klaster 3 su isključivo žene, a klaster 2 je između te dvije vrijednosti. Analizom razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u tri klastera ispitanika, a po načinu promjene fraktalne dimenzije temporalnog vektora (slika 5.15.) uočili smo da su ispitanici u većinom muškom prvom klasteru imali najniže vrijednosti R/S fraktalne dimenzije koje se nisu bitno mijenjale tijekom napora s time da su najviše porasle u drugoj četvrtini opterećenja da bi se u trećoj i četvrtoj četvrtini spustile na početne vrijednosti. Nadalje, treći klaster, koji su činile žene, imao je značajno više vrijednosti R/S fraktalnih dimenzija i uz opterećenje je umjesto porasta došlo do pada fraktalne dimenzije pa se najniža vrijednost vidi u trećoj četvrtini opterećenja uz neznatan oporavak na samome kraju opterećenja. Klaster broj dva, koji je bio miješane spolne strukture, više je nalikovao na pretežno muški klaster, što odgovara i omjeru spolova u klasteru dva. Kako je temporalni vektor u stvarnosti pomak točke električnog polja iz jedne milisekunde u iduću, taj vektor može se smatrati brzinom kretanja električnog polja, što znači da porast fraktalnosti opterećenjem u ove dvije četvrtine može značiti porast kaotičnosti promjene brzine električnog polja pod opterećenjem. U kasnijim fazama, pretpostavljivo zagrijavanjem muskulature i boljom prokrvljenošću, došlo je do smanjenja promjenjivosti brzine pomicanja električnog polja. Razdiobom ispitanika po spolu (slika 5.16.), u dva klastera, a po načinu promjene R/S fraktalne dimenzije centrifugalnog vektora evidentno je da su prvim klasterom dominirali muškarci, a drugim žene. Iz analize razdiobe R/S fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u dva klastera ispitanika (slika 5.17.), a po načinu promjene fraktalne dimenzije centrifugalnog vektora, bilo je vidljivo da su žene u drugom klasteru imale značajno veće vrijednosti R/S fraktalnih dimenzija, ali su i jedan i drugi klaster na opterećenje reagirali povećanjem fraktalnosti centrifugalnih vektora u drugoj četvrtini opterećenja da bi kasnije došlo do oporavka, slično kao i u temporalnom vektoru. Dobiveni rezultati mogu se tumačiti kao moguća prilagodba mišića na naprezanje.

6.3.1. RAZLIKE FRAKTALNE DIMENZIJE RAČUNATE *WAVELET* TRANSFORMACIJOM IZMEĐU EM KLASTERA ISPITANIKA

Za sve smo vrijednosti na jednak način proveli analizu podataka fraktalnih dimenzija izračunom *wavelet* transformacijom (tablica 5.4.). Važno je istaknuti da je od pet definiranih načina mjerenja, značajnost po spolu, dobi i utreniranosti, razlika nađena samo za temporalni vektor i to po spolu. U temporalnom vektoru (slika 5.18.) nađena su tri klastera od kojih je

prvi bio dominantno muški, treći je bio dominantno ženski, dok je drugi bio miješane spolne strukture. Nismo našli, ni u jednoj od pet metoda, značajnih razlika u razdiobi dobi ili utreniranosti između utvrđenih klastera. Nadalje, analiziranjem razdiobe *wavelet* fraktalne dimenzije tijekom četiri faze izlaganja vibracijama u dva klastera ispitanika definiranim po načinu promjene fraktalne dimenzije temporalnog vektora (slika 5.19.), bilo je vidljivo da su u klasteru u kojemu dominiraju žene, vrijednosti fraktalne dimenzije niže u odnosu na klaster kojim dominiraju muškarci. U mješovitom klasteru su vrijednosti fraktalne dimenzije bile između druga dva klastera. Također je i odgovor na opterećenje bio različit u ta tri klastera. Tako je u klasteru u kojem dominiraju žene u drugoj četvrtini medijan razdiobe opadao, a u klasteru s mnogo muškaraca bio je u blagom porastu. Iz svega navedenoga može se zaključiti da se fraktalna dimenzija dobivena *wavelet* analizom pokazala u našem istraživanju manje učinkovitom u razlučivanju klastera ispitanika od R/S analize. U slučaju temporalnog vektora izračun *wavelet* transformacijom pokazao je bitno drukčiju razdiobu ovisno o spolu i to na način da ženama pridružuje niže vrijednosti u odnosu na R/S algoritam. Kao zaključak može se reći da je riječ o neočekivanom rezultatu. Naime, kao što je u uvodu navedeno, od pet dostupnih metoda izračuna fraktalne dimenzije, namjerno su izabrane dvije ovdje primijenjene jer se dosta često razlikuju u procijeni fraktalne dimenzije. Za razliku od primjene drugih algoritama koji daju rezultat vrlo često blizu vrijednosti koja se dobije R/S algoritmom, nije bilo očekivano da će *wavelet* transformacija i to upravo za podatke o fraktalnoj dimenziji promjenjivosti temporalnog vektora, toliko odstupati od R/S algoritma. Iako se *wavelet* transformacija kroz literaturu i iskustva drugih autora pokazala izrazito primjenjiva i vjerodostojna kao jedan od pet algoritama izračuna fraktalne dimenzije, naša opažanja upućuje na potrebu testiranja i drugih metoda izračuna fraktalne dimenzije podataka vremenskih serija (*power spectrum, roughness-lenght* i variogram) (95 - 101).

7. ZAKLJUČCI

I. Istraživanje je bilo potaknuto pilot studijom u kojoj je skupini zdravih ispitanika snimana električna aktivnost paralumbalne muskulature tijekom opterećenja tijela na vibrirajućoj platformi. Izmjereni podaci o aritmičnom potencijalu duž osi X (lijevo – desno), osi Y (gore – dolje) i osi Z (naprijed – nazad) pokazali su da postoje značajne varijacije u oblaku podataka u faznom prostoru paralumbalne muskulature koji se također mijenjaju tijekom opterećenja. Na temelju toga postavljena je hipoteza da umaranje paralumbalne muskulature tijekom opterećenja na vibrirajućoj platformi može biti detektirano upravo u promjenama razdiobe električnog potencijala dobivenog mjerenjem u faznom prostoru.

II. U istraživanju je provedeno mjerenje tijekom izlaganja vibracijama cijeloga tijela u položaju koji aktivira paralumbalnu muskulaturu kod ukupno 44 ispitanika od kojih je bilo 30 muškaraca i 14 žena. 20 ispitanika bilo je mlađe od 24 godine, a 24 ispitanika bila su starija od te dobi. Ispitanici su na temelju sustavnog vježbanja bitnog za utreniranost paralumbalne muskulature podijeljeni u pet skupina. Dakle, od minimalne do izvrsne utreniranosti. Aktivnost je snimana uređajem Biopac Student Lab. u rezoluciji 1000 uzorkovanja u sekundi, i uporabom tri para elektroda postavljenih duž osi faznog prostora tijekom 200 sekundi. Iz prikupljenih podataka izostavljeni su dijelovi koji odgovaraju QRS kompleksu EKG-a, kako bi se umanjio utjecaj srčanoga rada na analizirane podatke. Iz podataka su rekonstruirani sljedovi pet različitih načina mjerenja električne aktivnosti pri čemu su za prva tri izdvojeni zapisi za svaku os. Za os X lijevo i desno, za os Y gore i dolje te za os Z naprijed i nazad. Također su izračunata dva vektora u faznom prostoru, od kojih jedan promatra put izražen u milivoltima, a koje je električno polje prešlo u jednoj milisekundi, odnosno između dva mjerenja i on je nazvan temporalnim vektorom. Drugi vektor definira koliko je pojedino mjerenje udaljeno od aritmetičkog središta oblaka podataka, te je nazvan centrifugalnim vektorom. Navedenih pet načina mjerenja rabljeno je za utvrđivanje bitnih značajnosti u vrijednostima fraktalne dimenzije pojedinog zapisa, pri čemu su fraktalne dimenzije računate dvjema odvojenim metodama: R/S algoritmom i *wavelet* transformacijom.

III. Rezultati mjerenja pokazuju da se izračunom fraktalne dimenzije zapisa R/S algoritmom značajne razlike između muških i ženskih ispitanika mogu naći najizraženije u zapisima osi Z (po četvrtinama, $p = 0{,}007$ do $p = 0{,}01$), dakle naprijed – nazad, što s velikom

vjerojatnošću odražava razliku u načinu stajanja i anatomske razdiobe ženske zdjelice i ženske paralumbalne muskulature u odnosu na mušku. Slično tome nađena je bitna razlika u temporalnom vektoru (po četvrtinama $p = 0,001$ do $p = 0,007$), pa se promjenjivost brzine kretanja električnog polja u milisekundi, ako se analizira fraktalnom dimenzijom po RS algoritmu, bitno razlikuje između muškaraca i žena. Što se tiče centrifugalnog vektora, udaljenosti od središta oblaka podataka, uočena je razlika samo u prvoj i drugoj četvrtini mjerenja ($p < 0,001$, odnosno $p = 0,002$), a slično tome uočena je razlika u prvoj i drugoj četvrtini mjerenja za kretanje točke mjerenja u smjeru osi X ($p = 0,004$, odnosno $p = 0,05$), dakle lijevo – desno. Ukoliko se rezultati R/S algoritmom izračunate fraktalne dimenzije analiziraju s obzirom na stupanj utreniranosti, uočeno je da postoji razlika samo duž osi Y i to u prvoj i drugoj četvrtini mjerenja ($p = 0,02$, odnosno $p = 0,03$). Uočene razlike po spolu upućuju na to da su vrijednosti fraktalne dimenzije računate R/S algoritmom bile veće u žena u odnosu na muške ispitanike, dakle vrijednosti fraktalne dimenzije po R/S algoritmu kod žena su bile veće. Što se tiče odnosa prema utreniranosti, tu su uočene značajke koje upućuju na to da postoji jedan složen odnos koji bi za potpuno definiranje tražio provođenje slične studije na znatno većem broju ispitanika.

IV. Jednaka analiza vrijednosti fraktalne dimenzije izračunate *wavelet* transformacijom pokazala se neovisnom o stupnju utreniranosti, a što se tiče razlike u spolu jedino je temporalni vektor pokazao značajnu razliku, po spolu, vrijednosti fraktalne dimenzije *wavelet* transformacijom (po četvrtinama, $p < 0,001$ do $p = 0,007$). Pri tome su vrijednosti fraktalne dimenzije u muškaraca bile veće u sva četiri razdoblja mjerenja u odnosu na žene, obrnuto u odnosu na razdiobu vrijednosti R/S algoritmom.

V. Druga faza analize bila je detekcija postojanja klastera sličnosti umaranja unutar pojedinog načina mjerenja električne aktivnosti paralumbalne muskulature pri čemu je rabljena metoda EM klastera s opcijom autodetekcije broja klastera. U podacima kretanja točke mjerenja duž osi X (lijevo – desno), detektirana su dva klastera koji međutim nisu pokazali nikakvu značajnu razliku po pitanju spola, dobi, utreniranosti ili pak po vrijednosti fraktalne dimenzije u pojedinim četvrtinama mjerenja. U kretanju električnog polja po osi Y (gore – dolje) tijekom faza izlaganja vibracijama, detektirana su tri klastera koji se nisu međusobno razlikovali po spolu, no umjereno su bile značajne razlike po dobi ($p = 0,03$). Nađena je značajna razlika po stupnju utreniranosti ($p = 0,01$) i vrlo značajne razlike u

fraktalnim vrijednostima tijekom faza izlaganja vibracijama ($p < 0,001$). Navedeno upućuje da podaci o kretanju položaja mjerenja duž osi Y (gore – dolje) u sebi sadrže bitne informacije o načinu umaranja muskulature koje nisu ovisne o spolu, međutim ovisne su i o dobi i o stupnju utreniranosti. Što se tiče kretanja po osi Z (naprijed – nazad), tu je utvrđena razlika u spolu ($p = 0,004$) što odgovara prije navedenim anatomskim razlikama muške i ženske zdjelice i također razlika u pojedinim četvrtinama mjerenja ($p < 0,001$). Temporalni vektor pokazuje samo razliku ovisno o spolu ($p = 0,02$) te razliku tijekom umaranja (po četvrtinama, od $p = 0,02$ do $p < 0,001$). Slično tomu, centrifugalni vektor također pokazuje razliku po spolu ($p < 0,001$), te razliku između sva četiri mjerenja ($p < 0,001$). Ukoliko pogledamo te razdiobe detaljnije, možemo vidjeti da kod gibanja duž osi Y (gore – dolje) postoji klaster najveće utreniranosti koji pokazuje i najniže vrijednosti fraktalne dimenzije dok ostala dva klastera pokazuju više vrijednosti proporcionalno tome koliko opada udio utreniranih ispitanika. Jednaka analiza primjenom EM klastera kod podataka dobivenih *wavelet* transformacijom pokazala je da detektirani klasteri unutar podataka o kretanju točke duž pojedine osi, odnosno temporalnog i centrifugalnog vektora nisu međusobno različiti po dobi i stupnju utreniranosti, a što se tiče razlike po spolu, jedina razlika uočena je kod temporalnog vektora ($p = 0,002$). Međutim, ako se gledaju pojedina mjerenja po četvrtinama svih pet načina mjerenja bili su značajno različiti između detektiranih klastera ($p < 0,001$). Prema navedenome može se zaključiti da EM klasteri u podacima koji su dobiveni *wavelet* transformacijom fraktalnih dimenzija u sebi sadrže klastere koji se međusobno značajno razlikuju po vrijednosti fraktalne dimenzije, međutim, ti klasteri nemaju nikakvu bitnu vezu ni sa spolom, ni s dobi, ni s utreniranošću ispitanika. Dakle mi za njih ne možemo smatrati da sadrže informaciju o načinu kako su se ispitanici umarali.

VI. Dvije primijenjene metode izračuna fraktalne dimenzije su se u ovom istraživanju pokazale bitno različitima, posebice pri obradi podataka fraktalne dimenzije temporalnog vektora. Za detekciju načina umaranja paralumbalne muskulature tijekom tjelovježbe naših ispitanika značajno više informacija dobiveno je izračunom fraktalne dimenzije R/S algoritmom pri čemu se najzanimljivijim pokazalo kretanje točke mjerenja duž osi Y (gore – dolje) te ponašanje temporalnog vektora, dakle brzine kretanja položaja mjerenja u pojedinoj milisekundi.

8. SAŽETAK

Cilj istraživanja: Istraživanje ponašanja električnog polja paralumbalne muskulature aktivirane vibracijama cijeloga tijela kao pokazateljem umaranja provedeno je na Medicinskom fakultetu Osijek na zdravim ispitanicima, pri čemu je utreniranost njihove paralumbalne muskulature procijenjena anamnestički ljestvicom od 5 stupnjeva.

Ispitanici: Uključena su 44 zdrava ispitanika (14 žena i 30 muškaraca od kojih je 20 bilo u dobi do 24 godine).

Metode: Električna aktivnost snimana je uređajem Biopac Student Lab. u rezoluciji 1000 uzorkovanja u sekundi, i uporabom tri para elektroda postavljenih duž osi faznog prostora tijekom 200 sekundi. Iz prikupljenih podataka izostavljeni su dijelovi koji odgovaraju QRS kompleksu EKG-a i rekonstruirani sljedovi pet različitih načina mjerenja električne aktivnosti pri čemu su za prva tri izdvojeni zapisi za svaku os. Za os X lijevo i desno, za os Y gore i dolje te za os Z naprijed i nazad, a izračunata su i dva vektora. Temporalni vektor pokazuje put u milivoltima između dva sukcesivna mjerenja, a centrifugalni vektor odražava udaljenost točke mjerenja od aritmetičkog središta oblaka podataka. Iz tako dobivenih vremenskih serija računata je fraktalna dimenzija R/S algoritmom i *wavelet* transformacijom.

Rezultati: Od rezultata izračunom fraktalne dimenzije zapisa R/S algoritmom izdvaja se kretanje električnog polja duž osi Y (gore – dolje) u prvoj i drugoj četvrtini mjerenja ($p = 0,02$, odnosno $p = 0,03$). Vrijednosti fraktalne dimenzije po R/S algoritmu u žena su bile veće. Jednaka analiza vrijednosti fraktalne dimenzije izračunate *wavelet* transformacijom (po četvrtinama, $p < 0,001$ do $p = 0,007$) pokazala je veće vrijednosti fraktalne dimenzije u muškaraca, obrnuto u odnosu na razdiobu vrijednosti po R/S algoritmu.

U drugoj fazi analize traženo je postojanje EM klastera po sličnosti promjene fraktalne dimenzije tijekom izlaganja vibracijama. U kretanju električnog polja po osi Y (gore – dolje), detektirana su tri klastera koji se nisu međusobno razlikovali po spolu, no umjereno su bile značajne razlike po dobi ($p = 0,03$). Nađena je značajna razlika po stupnju utreniranosti ($p = 0,01$) i vrlo značajne razlike u fraktalnim vrijednostima tijekom faze izlaganja vibracijama ($p < 0,001$).

Zaključci: Navedeno upućuje da podaci o kretanju položaja mjerenja duž osi Y (gore – dolje) u sebi sadrže bitne informacije o načinu umaranja muskulature koje nisu ovisne o spolu, međutim ovisne su i o dobi i o stupnju utreniranosti. Pri tome postoji klaster najveće

utreniranosti koji pokazuje i najniže vrijednosti fraktalne dimenzije dok ostala dva klastera pokazuju više vrijednosti proporcionalno tome koliko opada udio utreniranih ispitanika.
Jednaka analiza primjenom EM klastera kod podataka dobivenih *wavelet* transformacijom pokazala je da detektirani klasteri nemaju nikakvu bitnu vezu ni sa spolom, ni s dobi, ni s utreniranošću ispitanika pa ne sadrže informaciju o načinu kako su se ispitanici umarali.

Ključne riječi: mišići leđa, vibracija cijelog tijela, vibracija, vježba.

9. SUMMARY

ELECTRICAL ACTIVITY OF PARALUMBAR MUSCULATURE IN A THREE-DIMENSIONAL PHASE SPACE DURING EXPOSURE TO WHOLE-BODY VIBRATION

Aim: The study of the behavior of the electromagnetic field of the paralumbar musculature activated by the whole body vibration as an indicator of fatigue was performed at the Faculty of Medicine in Osijek on healthy subjects, where the training factor of their paralumbal musculature could be estimated by the anamnestic scale of five degrees.

Subjects: The study included 44 healthy subjects (14 women and 30 men, 20 of whom were aged up to 24 years old).

Methods: The electric activity was recorded by the Biopac Student Lab. at a resolution of one thousand increments per second, using three pairs of electrodes set along the axis of the phase spacing for 200 seconds. The parts corresponding to the QRS complex of the ECG and the reconstructed sequences of five different ways of measuring electrical activity were left out of the collected data, with the first three having separate records for each axis. Left and right for X axis, up and down for Y axis and forward and backward for Z axis, as well as the two calculated vectors. The temporal vector shows the path between the two successive measurements in millivolts and the centrifugal vector reflects the distance of the measurement point from the arithmetic center of the data cloud. The wavelet transformation and the R/S algorithm were used to determine the fractal dimension from the obtained time series.

Results: The results obtained by calculating the fractal dimension using the R/S algorithm showed the movement of the electric field along the Y axis (up and down) in the first and the second quarter of the measurement ($p = 0.02$ respectively $p = 0.03$). The values of fractal dimensions according to the R/S algorithm were higher in women. The same fractal dimension analysis calculated by the wavelet transformation (by quarters, $p < 0.001$ to $p = 0.007$) showed higher values of fractal dimensions in men, which contrasted the distribution of values according to the R/S algorithm.

In the second phase of the analysis the existence of an EM cluster was sought according to the similarity of the fractal dimension change during the exposure to vibrations. During the movement of the electric field on the Y axis (up and down), three clusters which did not differ

in relation to gender, but had some moderately significant differences in age, were detected ($p = 0.03$). Significant differences were also found in the training factor ($p = 0.01$) and in the fractal values during the vibration exposure phase ($p < 0.001$).

Conclusions: This indicates that the data on the movement of the measurement position along the Y axis (up and down) contain essential information on musculature fatigue, however, depending on both the age and the training factor. There is also a cluster of the highest training factor that showed the lowest values of the fractal dimension, while the other two clusters exhibited higher values according to the decrease of the share of surveyed subjects.

The same analysis using the EM cluster for data obtained by the wavelet transformation showed that the detected clusters did not have any significant relation to either gender or age, nor the training of the subjects, and thus did not contain information on how the subjects developed the fatigue.

Key words: back muscles, exercise, whole body vibration (WBV), vibration.

10. LITERATURA

1.) Cochrane DJ. The effect of Vibration Exercise on Aspects of Muscle Physiology and Muscular Performance, Dissertation, Massey Universety, Palmerston North, New Zealand, 2010.

2.) Whedon GD, Deitrick JE, Shorr E. Modification of the effects of immobilisation upon metabolic and physiological functions of the normal men by the use of oscillating bed. Am J Med. 1949;6:684-710.

3.) Biermann W. „Influence of cycloid vibration massage on trunk flexion“. American Journal of Physical Medicine. 1960;39:219-224.

4.) Nazarov V, Spivak G. Development of athlete's strength abilities by means of biomechanical stimulation method. Theory and Practice of Physical Culture, Moscow, 1985;12:445-450.

5.) Kunnemeyer J, Schmidtbleicher D. Die neuromuskulaire stimulation RNS, Leistungssport. 1997;2:39-42.

6.) „Mars 500 Scientific Protocols“. European Space Agency. Retrieved 31 January 2013.

7.) Rittweger J, Felsenberg D. Resistive Vibration Exercise Prevents Bone Loss During 8 Weeks of Strict Bed Rest in Healthy Male Subjects: Results from the Berlin Bed Rest (BBR) Study, 26th Annual Meeting of the American Society for Bone and Mineral Research, Poster 1145:2004.

8.) Belavy DL, Bock O, Börst H, Armbrecht G, Gast U, Rittweger J. i sur. The 2(nd) Berlin BedRest Study: protocol and implementation, J Musculoskelet Neuronal Interact. 2010;10:207-19.

9.) Belavy DL, Beller G, Ritter Z, Felsenberg D. Bone structure and density via HR-pQCT in 60d bed-rest, 2-years recovery with and without countermeasures., J Musculoskelet Neuronal Interact. 2011;11:215-26.

10.) Belavy DL, Beller G, Armbrecht G, Perschel FH, Fitzner R, Bock O i sur. Evidence for an additional effect of whole-body vibration above resistive exercise alone in preventing bone loss during prolonged bed rest., Osteoporos Int. 2011;22:1581-91.

11.) Kramer A, Gollhofer A, Ritzmann R.: Acute exposure to microgravity does not influence the H-reflex with or without whole body vibration and does not cause vibration-specific changes in muscular activity. J Electromyogr Kinesiol. 2013;23:872-8.

12.) Bosco C, Cardinale M, Tsarpela O. Influence of vibration on mechanical power and electromyogram activity in human arm flexor muscles. Eur J Appl Physiol Occup Physiol. 1999;79:306-11.

13.) Bosco C, Colli R, Introini E, Cardinale M, Tsarpela O, Madella A, Tihanyi J, Viru A. Adaptive responses of human skeletal muscle to vibration exposure. Clin Physiol. 1999;19:183-7.

14.) Bosco C, Iacovelli M, Tsarpela O, Cardinale M, Bonifazi M, Tihanyi J, Viru M, De Lorenzo A, Viru A. Hormonal responses to whole-body vibration in men. Eur J Appl Physiol. 2000;81:449-54.

15.) Cardinale M, Bosco C. The use of vibration as an exercise intervention. Exerc Sport Sci Rev. 2003;31:3-7.

16.) Cardinale M, Lim J. Electromyography activity of vastus lateralis muscle during whole-body vibrations of different frequencies. J Strength Cond Res. 2003;17:621-4.

17.) Sorichter S, Koller A, Haid C, Wicke K, Judmaier W, Werner P, i sur. Light concentric exercise and heavy eccentric muscle loading: effects on CK, MRI and markers of inflammation. Int J Sports Med. 1995.16(5):288-292.

18.) Albasini A, Krause M, Rembitzki I. Using Whole Body Vibration in Physical Therapy and Sport: Clinical Practice and Treatment Exercises. Churchill Livingstone: London; 2010.

19.) Lin-Rong L, Freddy MH, Lam M, Pang YC, Jones AYM, Gabriel YF. Leg Muscle Activity During Whole-Body Vibration in Individuals With Chronic Stroke, Med Sci Sports Exerc. 2014;46(3):537-545.

20.) Olivares PR, Gusi N, Parraca, Jose C. Adsuar and Borja Del Pozo-Cruz. The Journal of Alternative and Complementary Medicine. 2011;17(8):723-728.

21.) Tadao T, Makoto F, Hayao I, Shinya Y. Scandinavian Journal of Work, Environment & Health Vol. 12, No. 4, Fourth international symposium on hand-arm vibration: Helsinki, 6-8 May 1985 (August 1986), 280-283.

22.) Paschold W, Mayton AG. „Whole-Body Vibration: Building Awareness in SH&E.“ Professional Safety. 2011;56:30-5.

23.) Griffin MJ. Minimum health and safety requirements for workers exposed to hand-transmitted vibration and whole-body vibration in the European Union; a review. Occup.Environ.Med. 2004;61:387-397.

24.) Griffin MJ. Handbook of Human Vibration. Academic Press: London; 1996.

25.) Nigg BM, Wakeling JM. Impact forces and muscle tuning: a new paradigm. Exerc.Sport Sci. 2001;29:37-41.

26.) Sakakibara H, Kondo T, Miyao M, Yamada S. Digital nerve conduction velocity as a sensitive indication of peripheral neuropathy in vibration syndrome. Am J Ind Med. 1994 Sep;26(3):359-66.

27.) Stefanyshyn DJ, Nigg BM. Energy aspects associated with sport shoes. Sportverletz. Sportschaden 2000;14:82-9.

28.) Cardinale M, Rittweger J. Vibration exercise makes your muscles and bones stronger: fact or fiction? J Br.Menopause.Soc. 2006;12:12-8.

29.) Pope MH, Wilder DG, Magnusson ML. A review of studies on seated whole body vibration and low back pain. Proc IME H J Eng Med. 1999;213:435-46.

30.) Marín PJ, Rhea MR. Effects of vibration training on muscle power: a meta-analysis. Journal of strength and conditioning research / National Strength & Conditioning Association. 2010;24(3):871-8.

31.) Rittweger J. Vibration as an exercise modality: how it may work, and what its potential might be. European journal of applied physiology. 2010;108(5):877-904.

32.) Rauch F, Sievanen H, Boonen S, Cardinale M, Degens H, Felsenberg D, i sur. Reporting whole-body vibration intervention studies: recommendations of the International Society of Musculoskeletal and Neuronal Interactions. Journal of musculoskeletal & neuronal interactions. 2010;10(3):193-8.

33.) Abercromby AF, Amonette WE, Layne CS, McFarlin BK, Hinman MR, Paloski WH. Vibration exposure and biodynamic responses during whole-body vibration training. Medicine and science in sports and exercise. 2007;39(10):1794-800.

34.) Ritzmann R, Gollhofer A, Kramer A. The influence of vibration type, frequency, body position and additional load on the neuromuscular activity during whole body vibration. Eur J Appl Physiol. 2013;113:1-11.

35.) Cochrane DJ. The effect of Vibration Exercise on Aspects of Muscle Physiology and Muscular Performance. Dissertation, Massey Universety, Palmerston North: New Zealand; 2010.

36.) Guyton AC, Hall JE, Medicinska fiziologija, 9. izd. Medicinska naklada Zagreb: Zagreb; 1999., str. 67-78.

37.) Guyton AC, Hall JE, Medicinska fiziologija, 9. izd. Medicinska naklada Zagreb: Zagreb; 1999., str. 79-85.

38.) Guyton AC, Hall JE, Medicinska fiziologija, 9. izd. Medicinska naklada Zagreb: Zagreb; 1999., str. 597-608.

39.) Krmpotić-Nemanić J, Anatomija čovjeka, 5. izd. Medicinska naklada Zagreb: Zagreb; 1993, str. 200-205.

40.) Krmpotić-Nemanić J, Anatomija čovjeka, 5. izd. Medicinska naklada Zagreb: Zagreb; 1993, str. 188-192.

41.) Krmpotić-Nemanić J, Anatomija čovjeka, 5. izd. Medicinska naklada Zagreb: Zagreb; 1993, str. 228-230.

42.) Merletti R, Rainoldi A, Farina D. Myoelectric manifestations of muscle fatigue. In: Merletti, R., Parker, P. (Eds.), Electromyography – Physiology, Engineering, and Noninvasive Applications, first ed. John Wiley & Sons, Inc., Hoboken: New Jersey; 2004;233-258.

43.) Chaffin DB. Localized muscle fatigue-definition and measurement. J. Occup. Med. 1973;15:346-354.

44.) Merletti R, Rainoldi A, Farina, D. Myoelectric manifestations of muscle fatigue. In: Merletti, R., Parker, P. (Eds.), Electromyography – Physiology, Engineering, and Noninvasive Applications, first ed. John Wiley & Sons, Inc., Hoboken: New Jersey; 2004;233-258.

45.) Al-Mulla MR, Sepulveda F, Colley M, Al-Mulla F. Statistical class separation using sEMG features towards automated muscle fatigue detection and prediction. Proceedings of International congress on image and signal processing; Tianjin: China; 7–19 October 2009;1-5.

46.) Dee Unglaub S. Human Physiology: An Integrated Approach. Pearsin Benjamin Cummings; 2009:412.

47.) Sahlin K. Muscle fatigue and lactic acid accumulation. Acta physiologica Scandinavica. Supplementum. 1986.

48.) Bellinger AM, Reiken S, Dura M, Murphy PW, Deng S, Landry DW, i sur. Remodeling of ryanodine receptor complex causes „leaky“ channels: A molecular mechanism for decreased exercise capacity. Proceedings of the National Academy of Sciences of the United States of America. 2008;105:2198-202.

49.) Santulli G, Andrew M. Essential Roles of Intracellular Calcium Release Channels in Muscle, Brain, Metabolism, and Aging. Current Molecular Pharmacology. 2015;8:206-222.

50.) Shi J, Chang Q, Zheng YP. Feasibility of controlling prosthetic hand using sonomyography signal in real time: Preliminary study. J. Rehabil. Res. Develop. 2010;47:87-98.

51.) Mancini DM, Bolinger L, Li H, Kendrick K, Chance B, Wilson JR. Validation of near-infrared spectroscopy in humans. J. Appl. Physiol. 1994;77:2740-2747.

52.) Boushel R, Piantadosi CA. Near-infrared spectroscopy for monitoring muscle oxygenation. Acta Physiol Scand. 2000;168:615-22.

53.) Orizio C, Gobbo M, Diemont B, Esposito F, Veicsteinas A. The surface mechanomyogram as a tool to describe the influence of fatigue on biceps brachii motor unit activation strategy. Historical basis and novel evidence. Eur. J. Appl. Physiol. 2003;90:326-336.

54.) Basmajian J, De Luca C. Muscles Alive: Their Function Revealed by Electromyography. Williams and Wilkins; Baltimore, MD, USA. 1985.

55.) Raez MB, Hussain MS, Mohd-Yasin F. Techniques of EMG signal analysis: Detection, processing, classification and applications. Biol. Proc. Online. 2006;8:11-35.

56.) Donaldson S, Donaldson M, Snelling L. SEMG evaluations: An overview. Appl. Psychophysiol. Biofeedbac. 2003;28:121-7.

57.) Edwards RHT. Human muscle function and fatigue. In: Porter, R., Whelan, J. (Eds.), Human Muscle Fatigue: Physiological Mechanisms. Pitman Medical: London; 1981.

58.) Heimer S. Fatigue. In: Medved, R., (Ed.), Sports Medicine, second ed. pp. 1987:147-51.

59.) Vollestad NK. Measurement of human muscle fatigue. J. Neurosci. Meth. 1997;74:219-27.

60.) De Luca CJ. Myoelectrical manifestations of localized muscular fatigue in humans. Crit. Rev. Biomed. Eng. 1984;11:251-79.

61.) Farina D, Merletti R, Indino B, Nazzaro M, Pozzo M,. Surface EMG crosstalk between knee extensor muscles: experimental and model results. Muscle Nerve. 2002;26:681-95.

62.) Stegeman D, Hermens H. Standards for surface electromyography: The European project Surface EMG for non-invasive assessment of muscles (SENIAM) Available online: http://www.med.uni-jena.de/motorik/pdf/stegeman.pdf (accessed on 21 March 2011).

63.) Dimitrova NA, Arabadzhiev TI, Hogrel JY, Dimitrov GV. Fatigue analysis of interference EMG signals obtained from biceps brachii during isometric voluntary contraction at various force levels. J. Electromyograph. Kinesiol. 2009;19:252-58.

64.) Al-MullaMR, Sepulveda F, Colley M. A Review of Non Invasive Techniques to Detect and Predict Localised Muscle Fatigue. Sensors (Basel). 2011;11:3545-594.

65.) Cifrek M, Medved V, Tonković S, Ostojić S. Surface EMG based muscle fatigue evaluation in biomechanics. Clin Biomech (Bristol, Avon). 2009;24:327-40.

66.) Čalošević S, Analiza promjenjivosti prostornog kretanja električnog vektora ventrikula u EKG podacima viske rezolucije u usporedbi s R-R varijabilnošću, (doktorska disertacija), Osijek; 2012.

67.) Losa GA. The fractal geometry of life. Rev Biol. 2009;102(1):29-59.

68.) Goldberger AL, West BJ. Fractals in Physiology and Medicine. Yale J Biol Med. 1987;60:421-35.

69.) Mandelbrot BB. The fractal geometry of nature. WH Freeman: New York; 1982.

70.) Gleick J. Kaos: rađanje nove znanosti. Izvori: Zagreb; 1996.

71.) Stewart I. Kocka li se bog? – Nova matematika kaosa. Jesenski i Turk: Zagreb; 2003.

72.) May RM. Simple mathematical models with very complicated dynamics. Nature. 1976;261:459-67.

73.) Kaplan DT, Glas L. Understanding nonlinear dynamics. Springer-Verlag: New York; 1995.

74.) Goldberger AL, Amaral LAN, Hausdorf JM, Ivanov PCh, Peng C-K, Stanley HE. Fractal Dynamics in Physiology. Alterations with Disease and Aging. PNAS. 2002;99(suppl 1):2466-472.

75.) Goldberger AL. Non-linear dynamics for clinicians: chaos theory, fractals, and complexity at the bedside. Lancet. 1996;347:1312-14.

76.) Goldberger AL. Complex Systems. Proc Am Thorac Soc. 2006;3:467-72.

77.) Paar V, Pavin N, Rosandić M. Link between truncated fractals and coupled oscillators in biological systems. J Theor Biol. 2001;212(1):47-56.

78.) Murray JD. Mathematical Biology I: An intoduction. 3rd ed. Springer: New York; 2002.

79.) Sharma V: Deterministic Chaos and Fractal Complexity in the Dynamics of Cardiovascular Behavior: Perspectives on a New Frontier. The Open Cardiovascular Medicine Journal. 2009;3:110-23.

80.) Dinjar K, Marić S, Kurbel S. In search of real-time non invasive estimation ofmuscle fatigue during exertion: Can dispersion of the high resolution muscle electrical activity data provide new insights?, Acta Clinica Cro., vol56/2017. IN PRESS.

81.) Čalošević S, Dinjar K, Čalošević Su, Kurbel S, Steiner R. Hidden information in three-axial ECG data of normal subjects: Fractal dimension of corresponding points from successive QRS loops as a potential sport and age dependent marker. General Physiology and Biophysics, 2016.

82.) Čalošević S. Analiza promjenjivosti prostornog kretanja električnog vektora ventrikula u EKG podacima viske rezolucije u usporedbi s R-R varijabilnošću (doktorska disertacija). Osijek; 2012.

83.) Kurbel S., A vector-free ECG interpretation with P, QRS & T waves as unbalanced transitions between stable configurations of the heart electric field during P-R, S-T & T-P segments. Theor Biol Med Model. 2014 Feb 10;11:10. doi: 10.1186/1742-4682-11-10.

84.) Baraban V., Čalošević S., Kurbel S., Marić S., Karakteristike dijastoličke funkcije zdravih ispitanika dobivene analizom mikrovoltažne promjenljivosti izoelektričnih segmenata snimljenih triaksijalnim elektrokardiografom visoke rezolucije – odstupanja u ovisnosti o dobi i spolu. Cardiologia Croatica. Sep/Oct2014, Vol. 9 Issue 9/10, p 389-389. 1p.

85.) Baraban V. Usporedba mikrovoltažne promjenjivosti izoelektričnih segmenata sa R-R varijabilnošću EKG zapisa visoke rezolucije zdravih ispitanika (doktorska disertacija). Medicinski fakultet Osijek, Sveučilište Osijek; 2013.

86.) Ganong WF. Review of medical physiology. 23rd edition. New York: McGraw-Hill Medical; 2005:547-64.

87.) Hall JE. Guyton and Hall Textbook of Medical Physiology: Enhanced E-book. Elsevier Health Sciences; 2010:121-56.

88.) Podrid PJ, Malhotra R, Kakkar R, Noseworthy PA. Podrid's Real-World ECGs: A Master's Approach to the Art and Practice of Clinical ECG Interpretation - Volume 1: The Basics. 1st ed. Cardiotext Publishing; 2013:1-150.

89.) Lederer W. J. Cardiac electrophysiology and the electrocardiogram. In: Boron WF, Boulpaep EL. Medical Physiology, 2nd Updated Edition. Elsevier Health Sciences; 2012:504-28.

90.) Zhang Z, VanSwearingen J, Brach JS, Perera S, Sejdić E. Most suitable mother

wavelet for the analysis of fractal properties of stride interval time series via the average wavelet coefficient method. Comput Biol Med. 2017 Jan 1;80:175-84.

91.) Lorin P, Manceau C, Foubert F. Effect of vestibular neuritis on postural control using wavelets and fractal analysis. Rev Laryngol Otol Rhinol (Bord). 2010;13:235-41.

92.) Kurbel S, Dmitrović B, Marjanović K, Vrbanec D, Juretić A. Distribution of Ki-67 values within HER2 & ER/PgR expression variants of ductalbreast cancers as a potential link between IHC features and breast cancer biology. BMC Cancer. 2017; 29(17):231.

93.) Celeux G, Govaert G. A classification EM algorithm for clustering and two stochastic versions. Comput. Stat. Data Anal. 1992;14:315-32.

94.) Jeff Wu CF, On the Convergence Properties of the EM Algorithm, The Annals of Statistics Vol.11.1983;1:95-103.

95.) Singh A, Dandapat S.Block sparsity-based joint compressed sensing recovery of multi-channel ECG signals. Healthc Technol Lett. 2017;4:50-6.

96.) Sánchez C, Bueno-Orovio A, Pueyo E, Rodríguez B. Atrial Fibrillation Dynamics and Ionic Block Effects in Six Heterogeneous Human3D Virtual Atria with Distinct Repolarization Dynamics.Front Bioeng Biotechnol. 2017;5:29.

97.) Muhammad N, Bibi N, Mahmood Z, Akram T, Naqvi SR. Reversible integer wavelet transform for blind image hiding method. PLoS One. 2017;12(5):e0176979.

98.) Ansari N, Gupta A. Image Reconstruction using Matched Wavelet Estimated from Data Sensed Compressively using Partial Canonical Identity Matrix. IEEE Trans Image Process. 2017.

99.) Scheel C, Traulsen I, Auer W, Müller K, Stamer E, Krieter J. Detecting lameness in sows from ear tag-sampled acceleration data using wavelets. Animal. 2017;10:1-8.

100.) Chen T, Zhao S, Shao S, Zheng S. Non-invasive diagnosis methods of coronary disease based on wavelet denoising and sound analyzing. Saudi J Biol Sci. 2017;24:526-36.

101.) Ulukaya S, Serbes G, Sen I, Kahya YP. A lung sound classification system based on the rational dilation wavelet transform. Conf Proc IEEE Eng Med Biol Soc. 2016;2016:3745-48.

11. ŽIVOTOPIS

Rođen sam 3. listopada 1981. u Osijeku, Republika Hrvatska. Srednjoškolsko obrazovanje završio sam u Osijeku 2000. godine u Medicinskoj školi Osijek, smjer medicinski tehničar.

Godine 2001. upisao sam studij medicine na Medicinskom fakultetu Sveučilišta J. J. Strossmayera u Osijeku, na kojemu sam diplomirao 2007. godine.

Od 2007. do 2009. godine radio sam kao asistent na Katedri za anatomiju i neuroznanost Medicinskog fakulteta u Osijeku.

Znanstveni poslijediplomski studij *Biomedicina i zdravstvo* Medicinskog fakulteta u Osijeku pohađao sam i završio u periodu od 2007. do 2010. godine.

Od 2009. radim na Zavodu za maksilofacijalnu kirurgiju i oralnu kirurgiju KBC-a Osijek, gdje sam postao specijalist maksilofacijalne kirurgije 2013. godine.

Od 2015. do 2017. godine završio sam užu specijalizaciju iz plastične i rekonstruktivne kirurgije glave i vrata u KB Dubrava Zagreb.