

# Identifikacija gruč neločljivih motoričnih enot iz večkanalnih površinskih elektromiogramov dvoglave nadlahtne mišice

Leon Kutos<sup>1</sup>, Jakob Škarabot<sup>2</sup>, Aleš Holobar<sup>1</sup>

<sup>1</sup>Fakulteta za elektrotehniko, računalništvo in informatiko, Univerza v Mariboru, Maribor, Slovenija

<sup>2</sup>School of Sport, Exercise and Health Sciences, Loughborough University, Loughborough, Velika Britanija

E-pošta: [leon.kutos@um.si](mailto:leon.kutos@um.si), [j.skarabot@lboro.ac.uk](mailto:j.skarabot@lboro.ac.uk), [ales.holobar@um.si](mailto:ales.holobar@um.si)

## Identification of clusters of inseparable motor units from high-density electromyograms of biceps brachii muscle

**Abstract.** We analyzed the capability of previously introduced Convolution Kernel Compensation (CKC) method to identify clusters of motor units (MUs) that share similar motor unit action potentials (MUAPs) and, therefore, cannot be mutually discriminated by the decomposition of high-density surface electromyograms (hdEMG). The tests were performed on biceps brachii muscle because hdEMG decomposition yields relatively small number of individual MUs in this muscle.

In this study, we analyzed how many MUs of biceps brachii get merged into the same spike train by the CKC method due to MUAP similarity and what are the sensitivity and precision of MU discharge identification in merged spike trains. We compared these metrics with the identification of individual MUs in both synthetic and experimental hdEMG. In synthetic hdEMG with 20 dB noise, the number of identified MUs increased from  $5.2 \pm 2.8$  (individual MUs) to  $16.4 \pm 8.4$  MUs when merged MU spike trains were taken into consideration, in addition to individual MUs. Discharges of individual MUs were identified with sensitivity of  $77.0 \pm 15.8$  % and precision of  $86.1 \pm 25.4$  %, whereas the merged MUs were identified with sensitivity of  $79.6 \pm 15.7$  % and precision of  $97.4 \pm 11.8$  %. Similar results were observed also for noiseless hdEMG.

In experimental hdEMG signals from biceps brachii muscle of two young healthy individuals, the number of identified MUs increased from  $7.5 \pm 2.4$  (individual MUs) to  $21.9 \pm 17.6$  MUs (merged MU spike trains). Individual MUs were identified with sensitivity of  $83.3 \pm 15.9$  % and precision of  $80.0 \pm 19.0$  %, whereas when considering also merged MUs, the sensitivity and precision of MU discharge identification increased to  $82.3 \pm 22.4$  % and  $94.9 \pm 11.4$  %, respectively.

In conclusion, the merged MU spike trains obtained by hdEMG decompositions carry important information about the activity of skeletal muscles and can be used to increase the number of MUs identified from hdEMG.

## 1 Uvod

Dekompozicija večkanalnih površinskih elektromiogramov (EMG) na prispevke posameznih motoričnih enot (ME) je v zadnjih dveh desetletjih omogočila številne nove in vivo nevrofiziološke študije in vpogled

v mehanizme delovanja motoričnega sistema pri ljudeh [7][8][9]. Kljub velikemu uspehu pa se uspešnost identifikacije ME med posameznimi skeletnimi mišicami močno razlikuje [1]. Največje število ME (tudi do 50 ME na posamezno skrčitev) je razpoznano iz penatnih mišic spodnjih okončin, kot so prednja golenska mišica (tibialis anterior) ali dvoglava mečna mišica (gastrocnemius) [1], medtem ko je število razpoznanih ME veliko manjše v fuziformnih mišicah, kjer so vlakna paralelna s smerjo mišične skrčitve. To še posebej velja za dvoglavo nadlaktno mišico (biceps brachii). Slednja vsebuje relativno veliko število (~ 500) ME, ki si delijo številne anatomske podobnosti, kot so število in dolžina mišičnih vlaken, lokacija v mišičnem tkivu, in hitrost prevajanja akcijskih potencialov motoričnih enot (APME).

V [2] smo pokazali, da imajo takšne ME zelo podobne APME, izmerjene na površini kože nad mišico, in jih je zato težko medsebojno ločiti. Posledično je število razpoznanih posameznih ME v dvoglavi nadlaktni mišici relativno majhno (med 5 in 10 ME na mišično skrčitev) [1]. Hkrati pa je dvoglava nadlaktna mišica ena izmed bolj preučevanih mišic tako v nevrologiji kot tudi v biomehaniki in športnih znanostih.

V tej študiji smo preučili število posameznih ME, ki jih razpoznamo iz večkanalnih signalov EMG dvoglave nadlaktne mišice in število ME, ki jih lahko razpoznamo, ko se pri dekompoziciji signalov večkanalnih signalov EMG ne omejimo le na posamezne ME, temveč analizo razširimo tudi na gruče neločljivih ME. Prav tako smo preverili s kakšno natančnostjo (preciznostjo) in senzitivnostjo lahko razpoznamo proženja ME v gručah neločljivih ME in te vrednosti primerjali z vrednostmi popolnoma ločljivih ME, torej ME, ki jih uspemo v večkanalnih signalov EMG v celoti ločiti od prispevkov drugih ME.

Prispevek je razdeljen na štiri poglavja. Poglavje 2 opisuje uporabljeno metodologijo, ki vključuje simulacijo in merjenje eksperimentalnih večkanalnih površinskih signalov EMG in njihovo dekompozicijo na prispevke posameznih ME oziroma gruče ME. Poglavje 3 podaja rezultate dekompozicije simuliranih in eksperimentalnih signalov EMG, poglavje 4 pa diskusijo rezultatov in zaključke študije.

## 2 Metodologija

### 2.1 Simulirani večkanalni signali EMG

Ker natančnosti in senzitivnosti razpoznavne proženj ME ni mogoče natančno izračunati iz eksperimentalnih

signalov EMG, smo prvi del študije zasnovali na sintetičnih večkanalnih signalih EMG, ki smo jih tvorili s cilindričnim prostorskim modelom, opisanim v [3]. Simulirali smo pet dvoglavih nadlahtnih mišic, z eliptičnim prerezom velikosti 60×30 mm in s 500 naključno razporejenimi ME na mišico. Debelini kože in podkožnega tkiva sta bili 1 mm in 4 mm. Rekrutacija in velikost ME sta sledili Hennemanovemu principu velikosti [5] z veliko majhnimi ME, ki se rekrutirajo pri majhnih mišičnih silah in eksponentno manj velikimi ME, ki se rekrutirajo pri velikih mišičnih silah. Razpon velikosti ME je znašal od 24 do 2408 vlaken na ME, zadnja, največja ME, pa je bila rekrutirana pri 80% največje hotne sile (NHS). Prožilne trenutke ME smo generirali z modelom, ki je opisan v [4]. Rekrutirane ME so pričele prožiti s frekvenco 8 Hz, frekvenca proženja pa se je linearno zviševala s stopnjo simulirane mišične sile in je dosegla 35 Hz pri 100% NHS. Simulirali smo naslednje stopnje mišične skrčitve: 10%, 30%, 50%, 70% in 90% NHS.

ME so vsebovala vlakna dolžine 130±5 mm, prevodna hitrost APME pa je znašala 4,0±0,3 m/s. Simulirali smo polje 9×10 površinskih elektrod s polmerom 1 mm in z medelektrodno razdaljo 5 mm. Signale EMG smo vzorčili s frekvenco 2048 Hz. Testirali smo tako na brezšumnih signalih EMG kot na signalih z dodanim aditivnim šumom v razmerju signal-šum 20 dB.

## 2.2 Eksperimentalni večkanalni signali EMG

Eksperimentalne signale EMG smo posneli iz dvoglave nadlahtne mišice dveh zdravih mlajših preiskovancev (starost 30±1 let, telesna teža 87±9 kg, višina 1,83±0,04 m) s poljem 13×5 elektrod (GR08MM1305, OT Bioelettronica, Torino, Italija), nameščenim nad lateralno in medialno glavo mišice. Signale v dolžini 20 s smo posneli med izometričnimi mišičnimi skrčitvami pri konstantni obremenitveni v višini 10%, 30%, 50% in 70% NHS, pri čemer smo vsako meritev ponovili dvakrat.

Signale EMG smo vzorčili s 2048 Hz pri 16 bitni ločljivosti (Quattrocento, OT Bioelettronica, Torino, Italija) in za kasnejšo analizo shranili na disk osebnega računalnika. Študijo je odobrila etična komisija Loughborough University Ethics Committee in oba merjenca sta se pred zajemom signalov EMG seznanila z namenom študije in podala pisno prostovoljno soglasje.


## 2.3 Dekompozicija signalov EMG

Večkanalne signale EMG smo dekomponirali z metodo kompenzacije konvolutivnih jeder (ang. Convolution Kernel Compensation – CKC) [7], ki je vgrajena v programsko orodje DEMUSE [6]. Število dekompozicijskih tekov smo nastavili na 30. Metoda CKC vrne vlake impulzov (Slika 1), kjer vsak impulz predstavlja proženje ME.

V posameznem razpoznanem vlaklu impulzov so lahko prisotni prispevki več ME, ki se razlikujejo po višini impulzov. Zato smo v vsakem vlaklu impulzov, ki ga je razpoznala metoda CKC naredili dve segmentaciji impulzov. Prva segmentacija (SEG<sub>IME</sub>), ki je vgrajena v orodje DEMUSE [6], skuša iz posameznega vlaka impulzov razpoznati trenutke proženja ene same ME. Druga segmentacija (SEG<sub>PNR</sub>), je pragovna, izvedli pa smo jo tako, da smo postopoma zniževali prag segmentacije. Vse impulze nad pragom smo proglasili za proženja ME in za vsako pozicijo praga izračunali metriko impulz-šum (angl. Pulse-to-Noise Ratio – PNR), ki je bila vpeljana v [9] in jo podaja enačba (1):

$$PNR(t_j(n)) = 10 \cdot \log \left( \frac{E(t_j^2(n)|_{t_j(n)=1})}{E(t_j^2(n)|_{t_j(n)=0})} \right) \quad (1)$$

kjer je  $t_j(n)$  vlak impulzov, kot ga oceni CKC (Slika 1),  $E$  je matematično upanje,  $t_j(n)|_{t_j(n)=1}$  je segmentiran impulz, ki označuje razpoznan proženje ME, medtem ko  $t_j(n)|_{t_j(n)=0}$  označuje šum pod pragom segmentacije, vključno s prispevki ostalih ME (preslusi na nivoju ME). Prag segmentacije smo izbrali tako, da je maksimiziral metriko PNR vsakega razpoznanega vlaka impulzov  $t_j(n)$ . Poudarimo, da sta bili obe segmentaciji izvedeni popolnoma avtomatsko, brez kakršnegakoli ročnega urejanja rezultatov s strani človeškega operaterja.



Slika 1. Vlaka impulzov, kot jih iz večkanalnih signalov EMG oceni metoda CKC. Višina impulzov je nedoločljiva, zato je maksimalna višina impulzov v vlaklu normalizirana na 1.

Zgornji vlak impulzov vsebuje prispevke ene same ME, spodnji pa prispevke treh ME.

V primeru obeh segmentacij smo merili natančnost oziroma preciznost ( $Pr$ ) in senzitivnost ( $Se$ ) razpoznave proženj ME:

$$Pr = \frac{TP}{TP+FP}, \quad Se = \frac{TP}{TP+FN} \quad (2)$$

kjer so  $TP$  pravilno razpoznana,  $FP$  napačno razpoznana in  $FN$  nerazpoznana proženja ME. Z enačbo (1) smo zračunali tudi metriko PNR. Zabeležili smo skupno število ME, ki smo jih razpoznali iz posamezne mišične skrčitve. Pri sintetičnih signalih EMG smo kot referenčne vrednosti vzeli simulirane prožilne trenutke ME, pri čemer smo pri vrednotenju segmentacije SEG<sub>IME</sub> upoštevali simulirane prožilne trenutke ene ME, pri

segmentaciji  $SEG_{PNR}$  pa simulirane prožilne trenutke vseh tistih ME, ki so v segmentiran vlak impulzov prispevale vsaj 30% simuliranih proženj. Referenčni prožilni vzorci za segmentacijo  $SEG_{PNR}$  so torej lahko vsebovale prožilne trenutke več ME.


V primeru eksperimentalnih signalov EMG smo kot referenčne vlake impulzov vzeli rezultate dekompozicije CKC, ki jih je pregledal in ročno uredil ekspert z dvajsetletnimi izkušnjami dekomponiranja in urejevanja signalov EMG.

Statistične primerjave smo naredili z Wilcoxonovim testom predznačenih rangov, saj je Lillieforsov test zavrnil normalno porazdelitev vrednosti izmerjenih metrik.


### 3 Rezultati

#### 3.1 Simulirani večkanalni signali EMG

Slika 2 prikazuje število razpoznanih ME s segmentacijama  $SEG_{IME}$  in  $SEG_{PNR}$ , vrednosti  $PNR$  ter preciznosti in senzitivnosti zaznavanja proženj ME za vse simulirane signale EMG brez dodanega šuma. Sliki 3 in 4 prikazujeta vrednosti za signale EMG z 20 dB šuma pri vseh stopnjah oziroma pri nizkih (10% in 30% NHS) stopnjah kontrakcije.




Slika 2. Število ME, njihove vrednosti PNR, preciznost (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz brezšumnih sintetičnih signalov EMG z vsemi stopnjami mišičnih skrčitev.



Slika 3. Število ME, vrednosti PNR, preciznost (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz sintetičnih signalov EMG pri 20 dB šuma in vseh stopnjah skrčitev.


#### 3.2 Eksperimentalni večkanalni signali EMG

Število ME, razpoznanih s segmentacijama  $SEG_{IME}$  in  $SEG_{PNR}$  in njihove vrednosti PNR prikazujeta zgornja

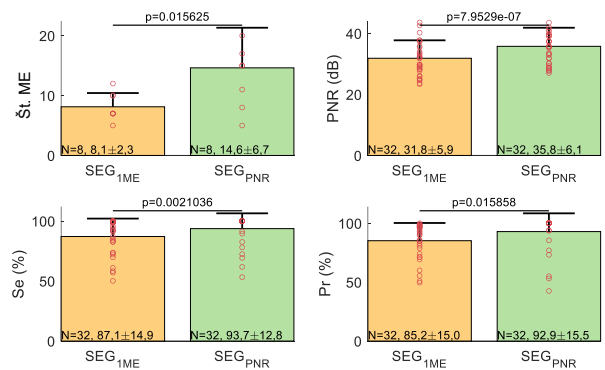


Slika 4. Število ME, vrednosti PNR, preciznost (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz sintetičnih signalov EMG pri 10% in 30% NHS in 20 dB šuma.

grafa na sliki 5. Preciznost Pr in senzitivnost Se proženj ME, razpoznanih iz eksperimentalnih večkanalnih signalov EMG prikazujeta spodnja grafa na sliki 5. Slika 6 podaja rezultate za skrčitve pri 10% in 30% NHS, slika 7 pa za skrčitve pri 50% in 70% NHS.



Slika 5. Število ME, njihove vrednosti PNR, preciznost (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz eksperimentalnih signalov EMG z vsemi stopnjami skrčitev.



Slika 6. Število ME, vrednosti PNR, preciznosti (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz eksperimentalnih signalov EMG, posnetih pri 10% in 30% NHS.

### 4 Diskusija

V tej študiji smo pokazali, da lahko z upoštevanjem gruđ neločljivih ME statistično značilno povečamo število ME, ki jih razpoznamo iz večkanalnih površinskih signalov EMG dvoglave nadlahtne mišice (Slike 2-7). V

primeru brezšumnih sintetičnih signalov EMG se je število razpoznanih ME v povprečju povečalo za 27 %, v primeru 20 dB šuma pa za 315 %. V primeru eksperimentalnih površinskih signalov EMG smo zaznali 292 % povečanje števila ME.

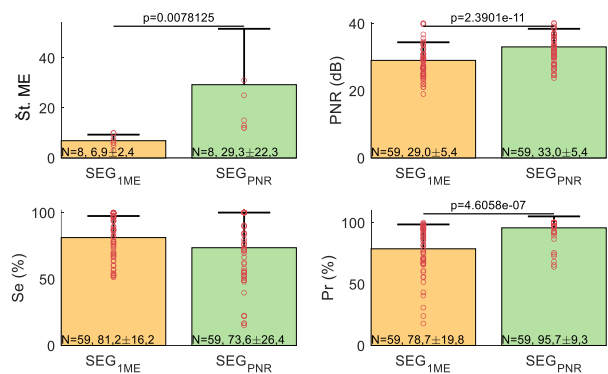
Povečala se je tudi preciznost avtomatske segmentacije proženj ME. V primeru brezšumnih sintetičnih signalov EMG se je dvignila iz 93,5 % na 98,5 %, v primeru 20 dB šuma pa iz 68,1 % na 97,4 %. V primeru eksperimentalnih signalov EMG je preciznost razpoznavanja težje določljiva, saj smo omejeni na primerjavo s tistimi ME, ki jih je s pomočjo avtomatske dekompozicije signalov EMG in ročnega urejanja razpoznal ekspert z dolgoletnimi izkušnjami dekomponiranja signalov EMG. Kljub temu smo v naši študiji zaznali statistično značilno povečanje preciznosti, in sicer iz iz 80,0 % na 94,9 % (Slika 5).

Prednost metrike PNR je, da jo lahko enako verodostojno uporabimo tako v primeru sintetičnih kot v primeru eksperimentalnih signalov EMG. Pri tem ne potrebujemo referenčnih vrednosti posameznih ME. V tej študiji smo pokazali, da se vrednost PNR statistično značilno poveča, ko v segmentacijo vključimo tudi impulze neločljivih oziroma slabo ločljivih ME (Slike 2-7). Prav tako smo pokazali, da lahko z maksimizacijo metrike PNR uspešno nastavimo prag segmentacije vlakov impulzov, ki z relativno veliko preciznostjo zajame proženja ene ali več ME.

Senzitivnost zaznave proženj ME je v gručah neločljivih ME nekoliko nižja od preciznosti. Čeprav je primerljiva s senzitivnostjo zaznave proženj posameznih ME (Slike 2-7), ostaja predmet prihodnjih preučevanj in nadaljnjih optimizacij tehnike segmentacije.

Naša študija ima nekaj pomembnih omejitev. Prvič, preučili smo le identifikacijo gruč ME v dvoglavi nadlahtni mišici. Ostalih mišic še nismo preučili. Drugič, uporabili smo standardne parametre dekompozicije CKC v orodju DEMUSE, občutljivosti predstavljenih rezultatov na spremembe teh parametrov pa nismo preučili. Tretjič, večji del študije temelji na sintetičnih signalih EMG z znanimi vzorci proženja ME. Eksperimentalne signale smo zajeli le v dveh zdravih merjencih, in sicer z namenom prikaza podobnosti rezultatov pri sintetičnih in eksperimentalnih signalih EMG. Četrto, naša študija ne podaja vpogleda v ocenjevanje fizioloških parametrov, kot so na primer frekvenca proženja ali prag rekrutacije iz obravnavanih neločljivih gruč ME. Slednje ostaja predmet nadaljnjih preučevanj.

Kljub naštetim omejitvam smo pokazali, da lahko z upoštevanjem gruč neločljivih ME bistveno povečamo število ME, ki jih razpoznamo iz večkanalnih površinskih signalov EMG in s tem bistveno izboljšamo robustnost dekompozicije na anatomske podobnosti ME v preučevani skeletni mišici. Slednje predstavlja velik korak dalje k prenosu dekompozicije signalov EMG iz akademskih raziskav v klinično prakso in v okolja izven raziskovalnih laboratorijev.



Slika 7. Število ME, njihove vrednosti PNR, preciznost (Pr) in senzitivnosti (Se) proženj ME, razpoznanih iz eksperimentalnih signalov EMG, posnetih pri 50% in 70% NHS.

## Zahvala

Raziskovalno delo je iz okvirnega programa EU za raziskave in inovacije, Obzorje Evropa, finančno podprla Evropska Komisija (projekt HybridNeuro, št. pog. 101079392). Sofinancirala ga je tudi Javna agencija za raziskovalno in inovacijsko dejavnost Republike Slovenije (raziskovalni program P2-0041).

## Literatura

- [1] Del Vecchio A, Holobar A, Falla D, Felici F, Enoka RM & Farina D (2020). Tutorial: Analysis of motor unit discharge characteristics from high-density surface EMG signals. *J Electromyogr Kinesiol* 53, 102426
- [2] Divjak M, Wiedemann LG, McDaid AJ & Holobar A (2020). On the Crosstalk in Motor Unit Spike Train Identification from High-Density Surface Electromyograms. In *Converging Clinical and Engineering Research on Neurorehabilitation IV*, 389–393. Springer International Publishing.
- [3] Farina D, Mesin L, Martina S & Merletti R (2004). A surface EMG generation model with multilayer cylindrical description of the volume conductor. *IEEE Trans Biomed Eng* 51, 415–426.
- [4] Fuglevand AJ, Winter DA & Patla AE (1993). Models of recruitment and rate coding organization in motor-unit pools. *J Neurophysiol* 70, 2470–2488.
- [5] Henneman E (1957). Relation between size of neurons and their susceptibility to discharge. *Science* 126, 1345–1347.
- [6] Holobar: DEMUSE tool - DEcomposition of MULTichannel Surface EMG: <https://demuse.feri.um.si/>
- [7] Holobar A & Zazula D (2007). Multichannel blind source separation using convolution Kernel compensation. *IEEE Trans Signal Process* 55, 4487–4496.
- [8] Holobar A, Farina D, Gazzoni M, Merletti R & Zazula D (2009). Estimating motor unit discharge patterns from high-density surface electromyogram. *Clin Neurophysiol* 120, 551–562.
- [9] Holobar A, Minetto MA & Farina D (2014). Accurate identification of motor unit discharge patterns from high-density surface EMG and validation with a novel signal-based performance metric. *J Neural Eng* 11, 016008.