

REKONSTRUKCIJA MIŠIČNE STRUKTURE MOTORIČNIH ENOT IZ SIGNALOV HD-sEMG Z UPORABO GLOBOKIH KONVOLUCIJSKIH NEVRONSKIH MREŽ

NIKO UREMOVIĆ, NIKO LUKAČ, ALEŠ HOLOBAR

Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko,
Maribor, Slovenija

niko.uremovic@um.si, niko.lukac@um.si, ales.holobar@um.si

V članku predlagamo metodo za rekonstrukcijo lokacije motoričnih enot skeletnih mišic iz večkanalnih površinskih elektromiogramov (angl. High-Density Surface Electromyogram, HD-sEMG) z uporabo globokih konvolucijskih nevronske mreže. Metoda najprej uporabi dekompozicijo signala HD-sEMG v nize akcijskih potencialov motoričnih enot (angl. Motor Unit Action Potential, MUAP). Nato se uporabi globoka konvolucijska nevronska mreža, da se iz akcijskih potencialov motoričnih enot določi globina, položaj, velikost in oblika vsake motorične enote. Metoda je ovrednotena na sintetičnih podatkih mišic biceps brachii.

DOI

[https://doi.org/
10.18690/um.feri.4.2026.6](https://doi.org/10.18690/um.feri.4.2026.6)

ISBN

978-961-299-111-1

Ključne besede:

konvolucijske nevronske
mreže,
večkanalni površinski
elektromiogrami,
identifikacija motoričnih
enot,
akcijski potenciali
motoričnih enot,
dekompozicija EMG



Univerzitetna založba
Univerze v Mariboru

DOI
[https://doi.org/
10.18690/um.feri.4.2026.6](https://doi.org/10.18690/um.feri.4.2026.6)

ISBN
978-961-299-111-1

RECONSTRUCTION OF MUSCLE MOTOR UNIT STRUCTURE FROM HD-sEMG SIGNALS USING DEEP CONVOLUTIONAL NEURAL NETWORKS

NIKO UREMOVIĆ, NIKO LUKAČ, ALEŠ HOLOBAR

University of Maribor, Faculty of Electrical Engineering and Computer Science,
Maribor, Slovenia

niko.uremovic@um.si, niko.lukac@um.si, ales.holobar@um.si

Keywords:

convolutional neural
networks,
high-density surface
electromyography,
muscle motor unit
reconstruction,
motor unit action potential,
EMG decomposition

In this paper, we propose a method for identifying the anatomic properties of skeletal muscle motor units from high-density surface electromyography (HD-sEMG) signals using deep convolutional neural networks. The method first applies decomposition of the HD-sEMG signal into sequences of motor unit action potentials (MUAPs). A deep convolutional neural network is then used to estimate the depth, location, size, and shape of each motor unit from the extracted MUAPs. The method is evaluated on synthetic datasets of the biceps brachii muscle.



University of Maribor Press

1 Uvod

Razumevanje organizacije in prostorskih informacij motoričnih enot (angl. motor unit, ME) skeletnih mišic je ključno za analizo nevromišične aktivnosti, diagnostiko živčno-mišičnih obolenj ter razvoj naprednih sistemov za povratne informacije o delovanju motoričnega sistema in nevroprotetiko [1]. Motorična enota predstavlja funkcionalno enoto, sestavljeno iz motoričnega nevrona in mišičnih vlaken, ki jih inervira (Merletti in Farina, 2016). Njena prostorska porazdelitev neposredno vpliva na obliko in amplitudo izmerjenih elektromiografskih signalov (Farina idr., 2004).

Večkanalni elektromiogram (HD-sEMG) omogoča neinvazivno zajemanje prostorsko bogatih informacij o električni aktivnosti mišic (Farina idr., 2004). Sodobne metode dekompozicije, kot je večkanalna slepa ločitev virov s kompenzacijo konvolucijskih jeder (angl. Convolution Kernel Compensation, CKC), ki jo je predlagal Holobar s sodelavci (Holobar in Zazula, 2007), omogočajo zanesljivo razčlenitev signalov HD-sEMG na zaporedja akcijskih potencialov motoričnih enot (APME, angl. Motor Unit Action Potential - MUAP). Takšne metode so bistveno razširile možnosti analize nevrnalnega nadzora skeletnih mišic v primerjavi s klasičnimi bipolarnimi sistemi EMG (Farina idr., 2025).

Kljub napredku na področju dekompozicije ostaja odprto vprašanje identifikacije anatomske lastnosti motoričnih enot iz površinskih meritev EMG. Večina obstoječih raziskav se osredotoča na časovno dinamiko proženja ali oceno prevodne hitrosti mišičnih vlaken (Holobar idr., 2014; Farina in Merletti, 2004; Dideriksen in Del Vecchio, 2023; Farina in Holobar, 2016), medtem ko je neposredna ocena prostorske strukture (globina, velikost, orientacija in oblika ME) bistveno manj raziskana. Prostorske metode kartiranja motoričnih enot sicer obstajajo, vendar praviloma temeljijo na hevrističnih metrikah amplitude ali centroida porazdelitve signala (Cescon idr., 2007; Merletti idr., 2008; Caspo idr., 2015).

Vzporedno z razvojem HD-sEMG je globoko učenje doseglo izjemne uspehe pri modeliranju kompleksnih prostorsko-časovnih podatkov (Bao idr., 2022; Zaim idr., 2025; Deji Dere in Lee, 2023; Cote-Allard idr., 2020; Rajapriya idr., 2021). Konvolucijske nevronske mreže (CNN) so se izkazale kot učinkovite pri analizi biosignalov, vključno s signali EMG, predvsem za klasifikacijske naloge (Zhai idr., 2017; Ameri idr., 2018; Farrukh Qureshi idr., 2022). Vendar je uporaba globokih

modelov za regresijsko rekonstrukcijo fizioloških parametrov motoričnih enot iz njihovih akcijskih potencialov še vedno omejena.

V tem delu predlagamo metodo za rekonstrukcijo prostorske strukture motoričnih enot iz signalov HD-sEMG. Metoda najprej uporabi preverjeno dekompozicijsko ogrodje CKC za ekstrakcijo APME, nato pa prostorsko-časovno globoko konvolucijsko mrežo za regresijo parametrov najmanjše oklepajoče elipse, ki aproksimira presek motorične enote. Parametrizacija elipse omogoča kompaktno, interpretabilno in fiziološko smiselno predstavitev strukture ME.

Glavni izvirni prispevki članka so:

- Nov pristop za rekonstrukcijo fizične strukture motoričnih enot neposredno iz APME.
- Prostorsko-časovna konvolucijska nevronska arhitektura za regresijo parametrov MVEE.
- Sistematična evalvacija na sintetični mišici biceps brachii z nadzorovanimi fiziološkimi parametri.
- Kvantitativna primerjava z referenčnimi regresijskimi metodami.

Predlagani pristop predstavlja korak proti neinvazivni 3D rekonstrukciji mišične mikrostrukture in odpira možnosti za nadaljnje vključevanje fizikalno informiranih modelov v globoko učenje za analizo elektrofizioloških signalov.

2 Metodologija

Predlagana metoda rekonstruira strukturo mišičnih motoričnih enot z dekompozicijo signala HD-sEMG v APME, nato pa uporabi globoko konvolucijsko nevronsko mrežo (angl. convolutional neural network, CNN) za izločanje značilnic iz posameznih APME in napove globino, lokacijo, velikost in obliko vsake motorične enote.

V prvem koraku se signal HD-sEMG dekomponira na posamezne APME z uporabo večkanalne slepe ločitve izvorov (angl. Blind Source Separation, BSS) (Holobar in Farina, 2014), in sicer z uporabo kompenzacije konvolucijskih jeder (angl. Convolutional Kernel Compensation, CKC) (Holobar in Zazula, 2007). Rezultat

tega koraka je signal dimenzij ($N_{MU} \times H \times W \times T$), kjer N_{MU} označuje število razpoznanih motoričnih enot, H in W označujeta višino in širino mreže elektrod (izraženi v številu kanalov), T pa označuje število vzorcev APME.

V naslednjem koraku globoka CNN izvleče značilnice posameznih APME in rekonstruira fiziološke značilnosti motorične enote z oceno elipse, ki najbolj ustreza preseku vlaken motorične enote neposredno pod mrežo elektrod. Elipsa je bila izbrana, ker zelo verodostojno predstavlja obliko preseka večine motoričnih enot in jo je mogoče opredeliti z le nekaj parametri: središče $y_0 \in \mathbb{R}^+$, $x_0 \in \mathbb{R}$, ki ustreza globini in prečnemu odmiku središča motorične enote od središča elektrode, polosi $a \in \mathbb{R}^+$, $b \in \mathbb{R}^+$, ki opredeljujeta velikost in obliko (sploščenost) preseka motorične enote, in nazadnje kot $\theta \in [0, \pi]$, ki opredeljuje nagib preseka motorične enote.

Arhitektura globoke CNN je podrobno opredeljena v algoritmu 1 in na sliki 1 ter je povzeta v naslednjih korakih:

1. Prostorske značilnosti signala se izločijo iz vsakega okvirja z uporabo dveh 2D konvolucijskih plasti z velikostjo jedra 3×3 in plasti maksimalnega združevanja (angl. max pooling) z enako velikostjo jedra in razvlačenjem velikosti 1. Po vsaki plasti se uporabi aktivacija ReLU.
2. Izločene prostorske informacije se v vsakem časovnem koraku izravnavajo v vektor.
3. Časovne značilnosti se nato izločijo iz tako pridobljenega signala z uporabo treh 1D konvolucijskih plasti z velikostjo jedra 3. Po vsaki plasti se uporabi aktivacija ReLU.
4. Prostorsko-časovne informacije se ponovno izravnavajo v en sam vektor.
5. Trije polnopolovzani sloji se uporabijo za interpretacijo prostorsko-časovnega kodiranja v parametre elipse, ki opredeljujejo fiziološke lastnosti motorične enote vhodnega signala. Aktivacija ReLU se ponovno uporabi po vsakem sloju.


```

procedure CNN2D_INIT( $n_{feat}$ ,  $n_{conv}$ ,  $n_{linear1}$ ,  $n_{linear2}$ ,  $T$ )
   $k_{pooling} \leftarrow 3$ 
   $k_{Conv2D} \leftarrow 3$ 
   $k_{Conv1D} \leftarrow 3$ 
   $p_{pooling} \leftarrow 1$ 
   $H_i, W_i = H - k_{Conv2D} + 1, W - k_{Conv2D} + 1$ 
   $H_p, W_p = \lfloor \frac{H_i + 2 * p_{pooling} - 1}{k_{pooling}} + 1 \rfloor, \lfloor \frac{W_i + 2 * p_{pooling} - 1}{k_{pooling}} + 1 \rfloor$ 
   $H_h, W_h = H_p - k_{Conv2D} + 1, W_p - k_{Conv2D} + 1$ 
   $Conv2D_i \leftarrow Conv2D(n_{feat}, n_{conv}, (k_{Conv2D}, k_{Conv2D}))$ 
   $MaxPool2D \leftarrow MaxPool2D((k_{pooling}, k_{pooling}), p_{pooling})$ 
   $Conv2D_h \leftarrow Conv2D(n_{conv}, n_{conv}, (k_{Conv2D}, k_{Conv2D}))$ 
   $Conv1D_i \leftarrow Conv1D(H_p * W_p * n_{conv}, n_{conv}, k_{Conv1D})$ 
   $Conv1D_h \leftarrow Conv1D(n_{conv}, n_{conv}, k_{Conv1D})$ 
   $Conv1D_o \leftarrow Conv1D(n_{conv}, n_{conv}, k_{Conv1D})$ 
   $Linear_i \leftarrow Linear(n_{conv} \cdot H_h \cdot W_h \cdot T, n_{linear1})$ 
   $Linear_h \leftarrow Linear(n_{linear1}, n_{linear2})$ 
   $Linear_o \leftarrow Linear(n_{linear2}, 5)$ 

procedure FORWARD( $MUAP$ )
   $h \leftarrow ReLU(Conv2D_i(MUAP))$ 
   $h \leftarrow MaxPool2D(h)$ 
   $h \leftarrow Flatten_{HW}(ReLU(Conv2D_h(h)))$ 
   $h \leftarrow ReLU(Conv1D_i(h))$ 
   $h \leftarrow ReLU(Conv1D_h(h))$ 
   $h \leftarrow Split_{HW}(Flatten_T(ReLU(Conv1D_o(h))))$ 
   $h \leftarrow ReLU(Linear_i(h))$ 
   $h \leftarrow ReLU(Linear_h(h))$ 
   $h \leftarrow ReLU(Linear_o(h))$ 
  return  $h$ 

```


Algoritem 1: Cevovod predlagane arhitekture globoke CNN z uporabo prostorskih in časovnih konvolucijskih slojev.



Slika 1: Predlagana globoka konvolucijska nevronska arhitektura
Vir: lasten


2.1 Sintetični podatki

Metoda je bila eksperimentalno ovrednotena na množici sintetičnih podatkov mišice biceps brachii. Simulacije so osnovane na modelih rekrutacije ME (Fuglevand idr., 1993) in prostorskega prevodnika (Farina in Merletti, 2001). Generiranih je bilo 10 podmnožic vzorcev različnih sintetičnih oseb, pri čemer so bile uporabljene različne fiziološke lastnosti, kot sta debelina podkožne maščobe in prevodna hitrost tkiva. Za vsako osebo so bili na mreži 10×9 elektrod z medelektrodo razdaljo 4 mm simulirani APME 500 motoričnih enot, vsak APME v dolžini 256 vzorcev. Slika 2 prikazuje podatke APME za dve večji motorični enoti.



Slika 2: Primeri APME različnih motoričnih enot.


Vir: lasten




Slika 3: Struktura simulirane mišice biceps brachii, sestavljena iz 500 motoričnih enot. Vlanka motoričnih enot so predstavljena z različnimi barvami. Črni diamanti predstavljajo centre motoričnih enot.

Vir: lasten

APME vsake osebe je bil povezan s fiziološkimi značilnostmi pripadajoče motorične enote, ki so bile uporabljene v simulacijskem procesu. Pri modeliranju motoričnih enot smo se osredotočili na strukturo mišičnih vlaken. Struktura vsake motorične enote je bila opisana z 25 do 1500 vlakni. Simulirana mišična vlakna so prikazana na sliki 3 v različnih barvah, črni rombi pa označujejo središča motoričnih enot. Ker so mišična vlakna, ki tvorijo isto motorično enoto, tesno stisnjena skupaj in imajo ovalno obliko, smo se odločili, da bomo za opisovanje posameznih motoričnih enot uporabili elipse.



(a) Mišična vlakna in najmanjši oklepajoči elipsoid ene izmed večjih motoričnih enot (#90) v središču mišice.



(b) Mišična vlakna in najmanjši oklepajoči elipsoid ene izmed večjih motoričnih enot (#90) na robu mišice.

Slika 4: Primera struktur motoričnih enot, predstavljenih z mišičnimi vlakni. Izrisana je oklepajoča elipsa z najmanjšo površino (MVEE), s katero v kompaktni obliki predstavimo približno strukturo motorične enote.

Vir: lasten

Da bi natančno opredelili mišična vlakna, ki tvorijo motorično enoto, smo presek mišičnih vlaken aproksimirali tako, da smo njihova središča prilagodili v najmanjšo možno oklepajočo elipso. V splošnem se problem v poljubnem številu dimenzij

imenuje oklepajoči elipsoid z najmanjšim volumnom (angl. Minimum Volume Enclosing Ellipsoid, MVEE), za katerega približek obstaja učinkovit optimizacijski algoritem. V našem primeru gre v 2-dimenzionalnem prostoru za iskanje oklepajoče ellipse z najmanjšo površino. Algoritem temelji na spustu baricentričnih koordinat, ki je opisan v (Kachiyan, 1996) in ovrednoten v (Todd in Yildirim, 2007). Slika 4 prikazuje dva primera različnih motoričnih enot, njunih mišičnih vlaken in izračunih MVEE ter njunih parametrov.

3 Rezultati

Podatkovna množica je bila razdeljena na podmnožice podatkov za učenje, validacijo in testiranje, tako da so bili izvzeti signali štirih od 10 oseb, dva za validacijo in druga dva za testiranje. Poskus je bil ponovljen v obliki 5-zložne križne validacije z različnimi subjekti v validacijskih in testnih množicah. Validacijska množica je bila uporabljena za zgodnje ustavljanje in za nalaganje uteži iz iteracije z najnižjo validacijsko izgubo po učenju. Testna množica je bila uporabljena za ovrednotenje modela po učenju. V poskusih poročamo o povprečni absolutni napaki (angl. Mean Absolute Error, MAE) napovedanih parametrov MVEE, kot tudi o povprečnem preseku nad unijo (angl. Intersection over Union, IoU) napovedanih in izračunanih MVEE, pri čemer sta obe merili povprečeni v petih iteracijah 5-zložne evalvacije.

Simuliranih 500 APME vseh 6 subjektov v naboru za učenje je bilo naključno premešano v vsaki epohi in posredovano v nevronske mreže v paketih velikosti 64. Mreža je bila učena na 3000 epohah oz. dokler se izguba na validacijski množici ni izboljšala v 500 epohah. Funkcija izgube, uporabljena v učenju, je bila srednja kvadratna napaka (angl. Mean Squared Error, MSE), uporabljena za 5 predvidenih parametrov MVEE (y_0, x_0, a, b, θ).

Rezultati analize občutljivosti so predstavljeni v tabeli 1.

Tabela 1: Primerjava uspešnosti prilagajanja parametrov MVEE pri izbiri različnih parametrizacij (števila konvolucijskih filtrov n_{conv}) globoke CNN.


Parametrizacija	MAE (x_0, y_0, a, b, θ) [mm, mm, mm, mm, rad]	IoU
$n_{\text{conv}} = 8$	0.217, 0.227, 0.134, 0.082, 0.687	0.7970
$n_{\text{conv}} = 16$	0.201, 0.215, 0.126, 0.063 , 0.670	0.8088
$n_{\text{conv}} = 32$	0.197 , 0.206 , 0.106 , 0.066, 0.923	0.8124

Rezultati primerjave z metodami merila uspešnosti so v tabeli 2.


Tabela 2: Primerjava rezultatov predlagane metode s standardnimi metodami meril uspešnosti.

Metoda	MAE (x_0, y_0, a, b, θ) [mm, mm, mm, mm, rad]	IoU
RF	1.682, 1.044, 0.157, 0.097, 0.718	0.2814
MLP	2.683, 2.585, 0.305, 0.331, 0.695	0.1471
Predlagana metoda	0.197, 0.206, 0.106, 0.066, 0.923	0.8124

Na sliki 5 predstavimo napovedane MVEE za motorične enote #90 in #85 in jih primerjamo z izračunanimi MVEE iz podatkov, uporabljenih v simulaciji.



(a) Mišična vlakna motorične enote (modro), izračunan MVEE (zeleno) in napovedan MVEE (rdeče), za motorično enoto #90.



(b) Mišična vlakna motorične enote (modro), izračunan MVEE (zeleno) in napovedan MVEE (rdeče), za motorično enoto #85.

Slika 5: Primera napovedi fizične strukture motorične enote iz simuliranih APME. Narisane so izračunana oklepajoča elipsa mišičnih vlaken iz podatkov simulacije ter napovedana oz. ocenjena elipsa z uporabo predlagane metode obdelave APME.

Vir: lasten

4 Zaključek

V članku smo predstavili metodo za rekonstrukcijo prostorske strukture motoričnih enot skeletnih mišic iz signalov HD-sEMG z uporabo globokih konvolucijskih nevronske mreže. Predlagani pristop združuje preverjeno dekompozicijo signalov z metodo CKC za ekstrakcijo APME ter prostorsko-časovno CNN za regresijo parametrov najmanjše oklepajoče elipse (MVEE), ki aproksimira presek motorične enote.

Eksperimentalni rezultati na sintetičnih podatkih mišice biceps brachii kažejo, da predlagana metoda dosega bistveno boljše rezultate v primerjavi z referenčnimi regresijskimi pristopi (RF, MLP) tako v smislu povprečne absolutne napake parametrov elipse kot tudi v metriki IoU. Povprečna vrednost IoU nad 0,8 potrjuje, da je iz APME mogoče zanesljivo rekonstruirati približno geometrijsko strukturo motorične enote.

Kljub spodbudnim rezultatom predpostavljamo, da neposredna regresija parametrov elipse ni optimalna formulacija problema. Posamezni parametri (zlasti orientacija in razmerje polosi) so med seboj močno korelirani, kar lahko vodi do numerične nestabilnosti in neenakomerno porazdeljene napake v prostoru parametrov. V prihodnjem delu načrtujemo uvedbo fizikalno informiranih učnih strategij, kjer bi bila funkcija izgube neposredno definirana v geometrijskem prostoru - npr. z maksimizacijo preseka nad unijo (IoU) med napovedano in referenčno elipso oziroma z optimizacijo razdalje med implicitnimi predstavitvami elips. Takšna formulacija bi lahko izboljšala stabilnost učenja in bolje odražala dejanski cilj rekonstrukcije prostorske strukture.

Pomemben naslednji korak predstavlja validacija metode na eksperimentalno izmerjenih podatkih HD-sEMG. Prehod s sintetičnih na realne podatke bo omogočil oceno robustnosti metode ob prisotnosti šuma, neidealne geometrije elektrod ter medosebne variabilnosti.

Predlagana metoda predstavlja prvi korak proti neinvazivni rekonstrukciji mikrostrukture skeletnih mišic iz površinskih meritev EMG ter odpira nove možnosti za integracijo globokega učenja in biofizikalnega modeliranja v analizi nevro-mišičnih sistemov.

Zahvala

Avtorji se zahvaljujejo za finančno podporo Javne agencije za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije (št. raziskovalnega programa P2-0041).

Literatura

- Ameri, A., Akhace, M. A., Scheme, E., & Englehart, K. (2018). Real-time, simultaneous myoelectric control using a convolutional neural network. *PLOS ONE*, 13(9), e0203835.
- Bao, T., Xie, S. Q., Yang, P., Zhou, P., & Zhang, Z.-Q. (2022). Toward robust, adaptive and reliable upper-limb motion estimation using machine learning and deep learning—A survey in myoelectric control. *IEEE Journal of Biomedical and Health Informatics*, 26(8), 3822–3835.
- Cescon, C., Madeleine, P., Graven-Nielsen, T., Merletti, R., & Farina, D. (2007). Two-dimensional spatial distribution of surface mechanomyographical response to single motor unit activity. *Journal of Neuroscience Methods*, 159(1), 19–25.
- Csapo, R., Malis, V., Sinha, U., & Sinha, S. (2015). Mapping of spatial and temporal heterogeneity of plantar flexor muscle activity during isometric contraction: Correlation of velocity-encoded MRI with EMG. *Journal of Applied Physiology*, 119(5), 558–568.
- Côté-Allard, U., Campbell, E., Phinyomark, A., Laviolette, F., Gosselin, B., & Scheme, E. (2020). Interpreting deep learning features for myoelectric control: A comparison with handcrafted features. *Frontiers in Bioengineering and Biotechnology*, 8, 158.
- Dere, M. D., & Lee, B. (2023). A novel approach to surface EMG-based gesture classification using a vision transformer integrated with convolutive blind source separation. *IEEE Journal of Biomedical and Health Informatics*, 28(1), 181–192.
- Dideriksen, J. L., & Del Vecchio, A. (2023). Adaptations in motor unit properties underlying changes in recruitment, rate coding, and maximum force. *Journal of Neurophysiology*, 129(1), 235–246.
- Farina, D., & Holobar, A. (2016). Characterization of human motor units from surface EMG decomposition. *Proceedings of the IEEE*, 104(2), 353–373.
- Farina, D., & Merletti, R. (2001). A novel approach for precise simulation of the EMG signal detected by surface electrodes. *IEEE Transactions on Biomedical Engineering*, 48(6), 637–646.
- Farina, D., & Merletti, R. (2004). Methods for estimating muscle fibre conduction velocity from surface electromyographic signals. *Medical & Biological Engineering & Computing*, 42(4), 432–445.
- Farina, D., Merletti, R., & Enoka, R. M. (2004). The extraction of neural strategies from the surface EMG. *Journal of Applied Physiology*, 96(4), 1486–1495.
- Farina, D., Merletti, R., & Enoka, R. M. (2025). The extraction of neural strategies from the surface EMG: 2004–2024. *Journal of Applied Physiology*, 138(1), 121–135.
- Fuglevand, A. J., Winter, D. A., & Patla, A. E. (1993). Models of recruitment and rate coding organization in motor-unit pools. *Journal of Neurophysiology*, 70(6), 2470–2488.
- Holobar, A., & Farina, D. (2014). Blind source identification from the multichannel surface electromyogram. *Physiological Measurement*, 35(7), R143–R165.
- Holobar, A., & Zazula, D. (2007). Multichannel blind source separation using convolution kernel compensation. *IEEE Transactions on Signal Processing*, 55(9), 4487–4496.
- Holobar, A., Minetto, M. A., & Farina, D. (2014). Accurate identification of motor unit discharge patterns from high-density surface EMG and validation with a novel signal-based performance metric. *Journal of Neural Engineering*, 11(1), 016008.
- Khachiyan, L. G. (1996). Rounding of polytopes in the real number model of computation. *Mathematics of Operations Research*, 21(2), 307–320.
- Merletti, R., & Farina, D. (2016). *Surface electromyography: Physiology, engineering, and applications*. John Wiley & Sons.
- Merletti, R., Holobar, A., & Farina, D. (2008). Analysis of motor units with high-density surface electromyography. *Journal of Electromyography and Kinesiology*, 18(6), 879–890.

- Qureshi, M. F., Mushtaq, Z., Rehman, M. Z. U., & Kamavuako, E. N. (2022). Spectral image-based multiday surface electromyography classification of hand motions using CNN for human-computer interaction. *IEEE Sensors Journal*, 22(21), 20676–20683.
- Rajapriya, R., Rajeswari, K., & Thiruvengadam, S. J. (2021). Deep learning and machine learning techniques to improve hand movement classification in myoelectric control system. *Biocybernetics and Biomedical Engineering*, 41(2), 554–571.
- Todd, M. J., & Yildirim, E. A. (2007). On Khachiyan's algorithm for the computation of minimum-volume enclosing ellipsoids. *Discrete Applied Mathematics*, 155(13), 1731–1744.
- Zaim, T., Abdel-Hadi, S., Mahmoud, R., Khandakar, A., Rakhtala, S. M., & Chowdhury, M. E. H. (2025). Machine learning- and deep learning-based myoelectric control system for upper limb rehabilitation utilizing EEG and EMG signals: A systematic review. *Bioengineering*, 12(2), 144.
- Zhai, X., Jelfs, B., Chan, R. H. M., & Tin, C. (2017). Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on convolutional neural network. *Frontiers in Neuroscience*, 11, 379.