

# Uporaba klasifikatorja MiniRocket v klasifikaciji starosti oseb na podlagi frekvenc proženja motoričnih enot med plantarno fleksijo

Domen Kavran<sup>\*,1</sup>, Borut Žalik<sup>\*,2</sup>, Domen Mongus<sup>\*,3</sup>, Niko Lukač<sup>\*,4</sup>, Mitja Geržević<sup>\*\*,†,5</sup>, Uroš Marušič<sup>\*\*,†,6</sup>, Rado Pišot<sup>\*\*,7</sup>, Boštjan Šimunič<sup>\*\*,8</sup>, Gianni Biolo<sup>‡,9</sup>, Angelina Passaro<sup>§,10</sup>, Stefano Lazzar<sup>‡,11</sup>, Mojca Gabrijelčič<sup>‡,12</sup>, Mladen Gasparini<sup>||,13</sup>, Aleš Holobar<sup>\*,14</sup>

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

<sup>\*\*</sup>Znanstveno-raziskovalno središče Koper, Koper, Slovenija, <sup>†</sup>Alma Mater Europaea – ECM, Maribor, Slovenija

<sup>‡</sup>Department of Medical, Surgical and Health Sciences, Division of Internal Medicine, University of Trieste, Trieste, Italy

<sup>§</sup>Department of Medical Sciences, Section of Internal and Cardiorespiratory Medicine, University of Ferrara, Ferrara, Italy

<sup>‡</sup>Department of Medical and Biological Sciences, University of Udine, Udine, Italy

<sup>||</sup>Nacionalni inštitut za javno zdravje, Ljubljana, Slovenija, <sup>||</sup>Oddelek za kirurgijo, Splošna bolnišnica Izola, Izola, Slovenija

E-pošta: <sup>1</sup>domen.kavran1@um.si, <sup>2</sup>borut.zalik@um.si, <sup>3</sup>domen.mongus@um.si,

<sup>4</sup>niko.lukac@um.si, <sup>5</sup>mitja.gerzevic@almamater.si, <sup>6</sup>uros.marusic@zrs-kp.si, <sup>7</sup>rado.pisot@zrs-kp.si,

<sup>8</sup>bostjan.simunic@zrs-kp.si, <sup>9</sup>biolo@units.it, <sup>10</sup>angelina.passaro@unife.it, <sup>11</sup>stefano.lazzar@uniud.it,

<sup>12</sup>mojca.gabrijelcic@nijz.si, <sup>13</sup>mladen.gasparini@sb-izola.si, <sup>14</sup>ales.holobar@um.si

## Usage of MiniRocket classifier in age classification of individuals based on the motor unit discharge rates during plantar flexion

*This paper presents and evaluates a method for age classification based on the motor unit discharge rates using the MiniRocket classifier. The proposed method was tested on a dataset of older and younger subjects that included EMG signals from gastrocnemius medialis, gastrocnemius lateralis, soleus, and tibialis anterior muscles during plantar flexion. The average F1-score for all muscles was  $0,562 \pm 0,259$  at 30% maximum voluntary contraction and  $0,525 \pm 0,277$  at 60% maximum voluntary contraction. Classification proved most successful when exclusively utilizing motor units of the gastrocnemius lateralis muscle. This led to the highest F1-score of  $0,770 \pm 0,204$  at 30% maximum voluntary contraction.*

*In the current form, the MiniRocket classifier proves to be less capable of capturing the different behaviors of motor units between young and old persons. Our results suggests that inclusion of other muscle features, such as exerted muscle force, is likely required to reach the classification rates of classifiers that are based on motor unit features carefully selected by human operators.*

## 1 Uvod

Medicinski podatki v obliki časovnih vrst, npr. elektromiogrami (EMG) in elektrokardiogrami (EKG), so bistvenega pomena za napredne znanstvene in klinične raziskave [1].

Signali EMG odražajo električne aktivnosti skeletnih mišic, s sodobnimi računalniškimi postopki pa je možno iz signalov EMG pridobiti tudi frekvence proženj posameznih motoričnih enot (angl. motor unit). Slednje so osnovne funkcionalne enote mišičnega sistema,

sestavljene iz motoričnega nevrona in množice mišičnih vlaken, ki jih nevron oživčuje. Za izvedbo dekompozicije signalov EMG so se uveljavile metode konvolutivnega slepega ločevanja izvora (angl. convolutive blind source separation) in metode globokega učenja [1].

V zadnjih letih so metode globokega učenja prevladale na področju klasifikacije signalov EMG. Konvolucijske nevronske mreže (angl. Convolutional Neural Networks - CNNs) so se izkazale za zelo uspešne pri klasifikaciji gibov dlani [2] in fizične aktivnosti [3]. Med naj sodobnejše metode klasifikacije časovnih vrst se uvršča MiniRocket [4]. Prav tako velja omeniti HIVE-COTE 2.0, ki združuje več algoritmov [5]. Med priznanimi metodami sta še globoki nevronske mreže InceptionTime [6] in TapNet [7].

V tem članku predstavimo metodo za klasifikacijo starosti na podlagi prožilnih hitrosti motoričnih enot z uporabo klasifikatorja MiniRocket. Delo je navdihnjeno s študijo [8], kjer so avtorji pokazali, da je možno s skrbno delitvijo motoričnih enot glede na prag rekrutacije iz stopnjevanja frekvenc proženja motoričnih enot ob naraščajoči mišični sili uspešno razlikovati med starejšimi in mlajšimi merjenci. V tej študiji smo preučili, ali so se te klasifikacije sposobni samostojno naučiti tudi sodobni klasifikatorji, ki temeljijo na lastnem učenju značilnic časovnih vrst. Izbrali smo klasifikator MiniRocket, saj le ta dosega zelo dobre rezultate nad podatkovnimi zbirkami v arhivu UCR [9]. Ta vključuje časovne vrste iz različnih področij medicinskih, industrijskih in simulacijskih meritev.

## 2 Zajem in analiza signala EMG


Za boljšo prostorsko ločljivost se uporablja EMG z visoko gostoto elektrod (angl. high-density EMG - hdEMG). Pred zajemom signala je treba izmeriti največjo hoteno skrčitev (angl. Maximum Voluntary

Contraction - MVC). To je največja sila, ki jo lahko posameznik zavestno proizvede s skrčitvijo določene mišice ali mišične skupine [10]. Meritve navadno zajamejo med večkratno ponovitvijo določenega profila sile skrčitve mišic, npr. v trikotni in trapezoidni obliki (Slika 1a).


V signalih EMG se število prisotnih motoričnih enot spreminja glede na stopnjo mišične skrčitve in utrujenosti [1]. Podrobnejša analiza je potrebna za boljše razumevanje mišične dinamike in funkcije skeletnih mišic. Osnovni korak za naprednejšo analizo je dekompozicija signala EMG. To je proces, ki omogoča razločevanje aktivnosti posameznih motoričnih enot med skrčitvijo mišic. Uspešna metoda je Convolution Kernel Compensation (CKC) [11]. Ta omogoča razpoznavo motoričnih enot, ki so bile aktivne med meritvijo EMG, in njihove binarizirane sekvence proženj skozi čas, t.i. binarnega vlaka proženj (angl. binary spike train).

Za podrobnejšo analizo prožitev motorične enote se izračuna t.i. glajena frekvenca proženja (angl. Smoothed Discharge Rate - SDR) [10]. Ta se pridobi tako, da se najprej izračuna trenutna frekvenca proženja (angl. Instantaneous Discharge Rate - IDR), ki se pridobi z (1) [12], kjer  $t_{i,j}$  predstavlja čas  $i$ -tega proženja  $j$ -te motorične enote,  $t_{i-1,j}$  pa čas  $i-1$ -tega proženja  $j$ -te motorične enote. IDR je časovno neenakomerno vzorčen, zato sledi interpoliranje oz. prevzorčenje na konstantno frekvenco vzorčenja. Tako frekvenco proženja opazujemo z enotnim časovnim korakom skozi celoten interval, od prvega do zadnjega proženja posamezne motorične enote. Na koncu še sledi uporaba nizkoprepustnega filtra [12]. Zgled analize je prikazan na Sliki 1.


$$IDR_j[t_{i,j}] = \frac{1}{t_{i,j} - t_{i-1,j}} \quad (1)$$




(a) Trapezoidna oblika profila sile skrčitve mišic. Izvedlo se je 5 sekundno postopno krčenje do 60% MVC, zadržanje skrčitve 15 sekund in nato 5 sekundno sproščanje.



(b) Dekomponirani prispevki motoričnih enot z metodo CKC.



(c) Urejeni binarni vlaki proženj razpoznanih motoričnih enot.



(d) SDR motoričnih enot, filtriran z nizkoprepustnim Butterworthovim filtrom 4. reda z lomno frekvenco 2 Hz.

Slika 1: Zgled analize dekomponiranih motoričnih enot.

### 3 Predlagana metoda klasifikacije

#### 3.1 Klasifikator MiniRocket

Metoda MiniRocket zelo učinkovito doseže vrhunsko zmogljivost klasifikacije časovnih vrst [4]. Metoda je nad velikimi podatkovnimi zbirkami tudi do 75-krat hitrejša od predhodne različice metode, imenovane Rocket [4]. Osrednji del metode MiniRocket je izračun značilnic, ki so rezultat 1D konvolucije časovnih vrst z naborom preddefiniranih jeder (angl. kernels) z 9 utežmi. Jedra se aplicirajo po celotni dolžini vhodne časovne vrste. Majhen nabor kratkih jeder in napredne matematične optimizacije (npr. izogibanje izvajanju množenja) prispevajo k učinkovitosti izračuna značilnic. To vodi k linearni časovni zahtevnosti [4].

Linearni klasifikator je uporabljen za klasifikacijo časovne vrste na osnovi njenih značilnic. Za zbirke z do 10.000 vzorci časovnih vrst v učni množici se priporoča učenje grebske regresije (angl. ridge regression), za večje učne množice pa se raje uporabi logistična regresija (angl. logistic regression). Specifike delovanja metode MiniRocket so predstavljene v [4].

#### 3.2 Klasifikacija merjenja

V predlagani metodi binarne klasifikacije starosti za vsako od mišic naučimo individualen klasifikacijski model MiniRocket [4]. Ta prejme na vhod SDR motorične enote, na izhodu pa vrne oznako merjenja (starejši/mlajši). Končna klasifikacija merjenja se izvede na osnovi t.i. večinskega glasu (angl. majority vote), ki predstavlja najpogostejšo oznako v množici. Zaporedje klasifikacije je prikazano na Sliki 2, kjer  $X$  predstavlja mišico z  $N_X$  razpoznanimi motoričnimi enotami.



Slika 2: Zaporedje klasifikacije merjenja.

### 4 Podatkovna zbirka

#### 4.1 Zajem EMG podatkov

V [10] so avtorji izvedli zajem hdEMG z namenom preučevanja vzorcev aktivacij mišic pred in po 14 dneh horizontalnega ležanja v postelji. Opravili so meritve kontrolirane isometrične plantarne fleksije dominantne noge z izvedbo trapezoidne oblike profila sile skrčitve mišice pri 30% in 60% MVC. Ta odstotka sta bila izbrana za analizo razlik med zmernimi in visokimi stopnjami skrčitev. Kožo so obrusili z abrazivno pasto, polje elektrod pa so napolnili s prevodnim gelom. Referenčno elektrodo so postavili na gleženj noge, ki so jo nato pritrdili na mehansko opornico pri 90-stopinjskem upogibu kolena [10].

Izvedene so bile meritve štirih mišic: gastrocnemius medialis (GM), gastrocnemius lateralis (GL), soleus (SO) in tibialis anterior (TA). Aktivnost vsake mišice so merili z uporabo polja elektrod velikosti  $13 \times 5$  elektrod. Skupno je bilo izmerjenih 64 kanalov EMG na mišico pri frekvenci vzorčenja 1024 Hz. Vsak merjenec je večkrat ponovil meritev (angl. trial) s 5 sekundnim postopnim krčenjem, kateremu je sledilo 15 sekundno

zadržanje skrčitve in nato 5 sekundno sproščanje. Med meritvami je bil izveden 90-sekundni premor [10].

Med sodelujočimi merjenci, ki smo jih analizirali v tej študiji, so bili izključno moški. Trije starejši merjenci so imeli povprečno starost  $58,4 \pm 3,3$  let, preostali trije mlajši merjenci pa so imeli povprečno starost  $23,1 \pm 2,9$  let. Pred pričetkom meritev so vsi udeleženci opravili zdravniški pregled. Kriteriji za izključitev so bili kajenje, redno uživanje alkohola, feromagnetni vsadki in različne bolezni [10].

## 4.2 Priprava podatkov

Izmerjene signale hdEMG v [10] so avtorji dekomponirali z metodo CKC [11]. Po ročnem urejanju rezultatov s strani raziskovalcev se je neustrezne motorične enote zavrlo. Treba je poudariti, da se število razpoznanih motoričnih enot razlikuje med merjenci, meritvami in med različnimi mišicami (Tabela 1).

Za vsako motorično enoto se je izračunala glajena frekvenca proženja SDR. Izračunana je bila tako, da se je po izračunu trenutne frekvence IDR izvedlo prevzorčenje na konstantno frekvenco vzorčenja 100 Hz. Temu je sledilo filtriranje z nizkopropustnim Butterworthovim filtrom 4. reda z lomno frekvenco 2 Hz [10].

## 4.3 Struktura podatkovne zbirke

Zbirka, ki smo jo uporabljali iz [10], vsebuje meritve šestih merjencev. Za pet od šestih merjencev so bile izvedene tri meritve pri 30% MVC in tri meritve pri 60% MVC. Izjema je en starejši merjenec, ki ima dve meritvi pri 30% MVC in tri meritve pri 60% MVC. Individualna meritva je namenjena izvedbi klasifikacije starosti merjenca. V Tabeli 1 so prikazani podatki o zbirki.

# 5 Rezultati

## 5.1 Postopek eksperimentov

Eksperimenti so bili izvedeni s stratificirano 9-kratno prečno validacijo (angl. stratified cross-validation). Vsaka od razdelitev podatkovne zbirke je vsebovala učno množico z meritvami dveh mlajših in dveh starejših merjencev, medtem ko smo v testni množici uporabili meritve od enega starejšega in enega mlajšega merjenca.

Za preizkus predlagane metode klasifikacije starosti se je uporabilo ločene meritve pri 30% in 60% MVC. Za vsako od mišic GM, GL, SO in TA se je ustvaril in naučil individualen klasifikacijski model MiniRocket s privzetimi parametri za izračun 10.000 značilnic in uporabo grebenske regresije. Preizkusilo se je upoštevanje razpoznanih motoričnih enot posameznih

mišic GM, GL, SO in TA, kot tudi uporaba vseh motoričnih enot teh štirih mišic.

Zaradi neuravnoteženega števila učnih meritev, kot tudi števila motoričnih enot v vsaki od razdelitev v prečni validaciji, se je za ocenitev uspešnosti uporabila metrika F1 (angl. F1-score). Pri binarni klasifikaciji ta omogoča uravnoteženje natančnosti (angl. precision) in priklica (angl. recall) [7]. Končni rezultati eksperimentov so se povprečili preko vseh razdelitev znotraj prečne validacije.

## 5.2 Rezultati klasifikacije starosti

Rezultati binarne klasifikacije so zapisani v Tabeli 2.

**Statistična analiza med mišicami, upoštevajoč individualno intenziteto skrčitve:** Nad rezultati mišic pri 30% MVC je Friedmanov test [10] dosegel  $\chi^2 = 11,452$ ,  $p = 0,0219$ . Takšen rezultat izkazuje statistično značilne razlike, kar pomeni, da upoštevanje motoričnih enot različnih mišic pri meritvah z 30% MVC vodi do različne uspešnosti klasifikacije. Podrobnejši Conoverjev test [10] je pokazal statistično značilne razlike med rezultati mišice GL proti vsem štirim mišicam ( $p = 0,035$ ), mišici SO ( $p = 0,0258$ ) in mišici TA ( $p = 0,0342$ ). Friedmanov test [10] je nad rezultati pri 60% MVC dosegel  $\chi^2 = 5,08387$ ,  $p = 0,2787$ , kar izkazuje statistično neznačilne razlike.

**Najuspešnejša mišica:** Klasifikacija je bila najuspešnejša pri upoštevanju izključno motoričnih enot mišice GL, kar je vodilo do  $F1 = 0,770 \pm 0,204$  pri 30% MVC. Pri 60% MVC je klasifikacija motoričnih enot na mišici GL vrnila  $F1 = 0,426 \pm 0,362$ .

**Povprečna uspešnost posamezne mišice, upoštevajoč obe intenziteti skrčitve:** Upoštevajoč rezultate pri 30% in 60% MVC, je uporaba motoričnih enot mišice GL vodila do najboljšega povprečja  $0,598 \pm 0,283$ . Najslabši povprečen rezultat  $0,497 \pm 0,259$  je bil dosežen z mišico GM. Upoštevanje motoričnih enot mišice SO je vodilo do rezultata  $0,569 \pm 0,272$ , medtem ko je bilo z mišico TA doseženo nižje povprečje  $0,552 \pm 0,285$ .

**Statistična analiza med dvema intenzitetama skrčitve, upoštevajoč vse mišice:** Friedmanov test [10] je nad rezultati obeh intenzitet skrčitve dosegel  $\chi^2 = 24,997$ ,  $p = 0,0948$ , kar izkazuje statistično neznačilne razlike. To pomeni, da v primeru upoštevanja vseh mišic intenzivnost skrčitve ne vpliva na uspešnost klasifikacije. To je razvidno tudi iz dokaj majhne razlike v povprečnih rezultatih, in sicer  $0,562 \pm 0,259$  pri 30% MVC in  $0,525 \pm 0,277$  pri 60% MVC.

Tabela 1: Število meritev in števila razpoznanih motoričnih enot individualne mišice med meritvami ob določenem % MVC za vsakega izmed merjencev v podatkovni zbirki ( $l$  = ni bilo razpoznanih motoričnih enot med meritvijo)

% MVC Merjenec	Mišica		Števila razpoznanih motoričnih enot med posamično meritvijo								Razred (S=starejši, M=mlajši)
			GM		GL		SO		TA		
	Št. meritev		30%	60%	30%	60%	30%	60%	30%	60%	
1	2	3	11,12	13,14,16	/,1	/,/,/	21,18	19,19,18	1,3	3,1,3	S
2	3	3	11,10,18	13,19,12	24,20,9	10,7,12	15,21,15	13,9,10	13,16,26	11,7,9	S
3	3	3	17,43,33	24,21,30	21,33,22	8,9,21	36,1,31	27,30,14	1,13,4	9,4,12	S
4	3	3	34,32,32	47,45,52	19,14,16	9,14,11	5,7,9	3,4,7	13,16,15	7,10,15	M
5	3	3	26,7,23	35,7,12	22,20,23	5,1,1	33,21,18	13,8,15	11,4,4	2,4,2	M
6	3	3	13,13,14	7,11,4	5,4,2	1,1,8	8,10,8	2,7,4	15,15,12	6,4,1	M

Tabela 2: Rezultati metrike F1 za klasifikacijo merjencev. Najboljši rezultati so označeni s krepko pisavo.

% MVC	30%	60%	Maksimum	Povprečje
Mišica				
4 mišice	0,519 ± 0,264	0,485 ± 0,223	0,519 ± 0,264	0,502 ± 0,244
GM	0,552 ± 0,197	0,441 ± 0,320	0,552 ± 0,197	0,497 ± 0,259
GL	<b>0,770 ± 0,204</b>	0,426 ± 0,362	<b>0,770 ± 0,204</b>	<b>0,598 ± 0,283</b>
SO	0,456 ± 0,347	<b>0,682 ± 0,196</b>	0,682 ± 0,196	0,569 ± 0,272
TA	0,511 ± 0,284	0,593 ± 0,285	0,593 ± 0,285	0,552 ± 0,285
Maksimum	<b>0,770 ± 0,204</b>	0,682 ± 0,196		
Povprečje	<b>0,562 ± 0,259</b>	0,525 ± 0,277		

## 6 Zaključek

V članku smo predstavili metodo klasifikacije starosti na podlagi prožilnih frekvenc motoričnih enot z uporabo klasifikatorja MiniRocket. Metodo smo preizkusili nad podatkovno zbirko starejših in mlajših merjencev, ki je vsebovala signale EMG štirih mišic noge med plantarno fleksijo. Nad signali EMG se je izvedla dekompozicija na prispevke motoričnih enot, temu pa je sledil izračun glajenih frekvenc proženj.

Klasifikacija starosti je bila najuspešnejša pri upoštevanju izključno motoričnih enot mišice gastrocnemius lateralis, kar je vodilo do rezultata  $F1=0,770 \pm 0,204$  pri 30% največje hotene skrčitve. Najslabši povprečni rezultati so bili doseženi s prožilnimi frekvencami mišice gastrocnemius medialis.

Avtorji v [8] so pokazali, da imajo motorične enote starejših oseb statistično značilno nižje frekvence proženja kot mlajše osebe. Slednje še zlasti velja za motorične enote z nižjih pragom rekrutacije [8]. Tudi v našem primeru so skrčitve pri 30% MVC dale boljše rezultate klasifikacije kot skrčitve pri 60% MVC. Slednje postane povedno, ko upoštevamo, da je dekompozicija signalov hdEMG pristranska, saj v signalih EMG večinoma razpozna največje, torej kasneje rekrutirane motorične enote [1]. Dekompozicija signalov pri 60% MVC je torej v veliki večini vsebovala motorične enote, ki so bile rekrutirane pri stopnji skrčitve nad 30% MVC. Kot so pokazali avtorji v [8], se prožilne frekvence teh motoričnih enot med starejšimi in mlajšimi osebami manj razlikujejo kot prožilne frekvence motoričnih enot, ki so rekrutirane pod stopnjo skrčitve 30% MVC.

Kljub temu je uspel pri 30% skrčitvi klasifikator MiniRocket zadovoljivo klasificirati le motorične enote mišice GL, ne pa tudi motorične enote mišic GM, SO in TA. Poudarimo, da je mišica TA pri plantarni fleksiji sodelovala le kot antagonistična mišica. Pripomogla je k stabilnejšemu zadrževanju giba, vidnejše vloge pa ni imela. Zato so rezultati te študije za mišico TA vsaj delno pričakovani. Slabo klasifikacijo motoričnih enot v mišicah GM, SO in delno tudi v GL pa lahko vsaj delno pojasnimo tudi z variabilnostjo prispevka posameznih mišic k plantarni fleksiji gležnja [10]. Razlike med prispevki različnih mišic ob ponovitvah gibov sodijo med večje izzive analize signalov EMG, ne glede na to, ali so značilnice izbrane s strani eksperta ali s pomočjo računalniškega algoritma, kot je MiniRocket.

Največja omejitev članka je majhno število merjencev v uporabljeni podatkovni zbirki. Prav tako je

bila klasifikacija izvedena le na osnovi aktivnosti največ štirih mišic med eno meritvijo plantarne fleksije.

Rezultati dokazujejo, da klasifikacija starih in mladih samo iz prožilnih frekvenc motoričnih enot z klasifikatorjem MiniRocket ne daje zadovoljivih rezultatov. V nadaljnjih raziskavah nameravam v klasifikacijo poleg prožilnih frekvenc motoričnih enot vključiti še podatke o trenutni proizvedeni sili med plantarno fleksijo, saj bi s tem vsaj delno zajeli tudi biomehanske lastnosti preučevanih mišic.

## Zahvala

Raziskovalno delo v danem prispevku je sofinancirala Javna agencija za raziskovalno in inovacijsko dejavnost Republike Slovenije, ter Ministrstvo za notranje zadeve, v sklopu ciljnega raziskovalnega projekta P2-0041.

Zajem signalov EMG je potekal v okviru raziskovalnega projekta PANGeA (Telesna dejavnost in prehrana za kakovostno staranje), podprtega s strani Programa čezmejnega sodelovanja Slovenija, Italija 2007–2013, št. donacije 042–2/2009.

## Literatura

- [1] A. Holobar, D. Farina, Noninvasive Neural Interfacing With Wearable Muscle Sensors: Combining Convolutional Blind Source Separation Methods and Deep Learning Techniques for Neural Decoding, *IEEE Signal Processing Magazine* 38 (4) (2021) 103–118.
- [2] A. R. Asif, A. Waris, S. O. Gilani, M. Jamil, H. Ashraf, M. Shafique, I. K. Niazi, Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG, *Sensors* 20 (6) (2020).
- [3] F. Demir, V. Bajaj, M. Ince, S. Taran, A. Sengur, Surface EMG signals and deep transfer learning-based physical action classification, *Neural Computing and Applications* 31 (12 2019).
- [4] D. Kavran, B. Žalik, N. Lukač, Comparing Beta-VAE to WGAN-GP for Time Series Augmentation to Improve Classification Performance, in: A. P. Rocha, L. Steels, J. van den Herik (Eds.), *Agents and Artificial Intelligence*, Springer International Publishing, Cham, 2022, pp. 51–73.
- [5] M. Middlehurst, J. Large, M. Flynn, J. Lines, A. Bostrom, A. Bagnall, HIVE-COTE 2.0: a new meta ensemble for time series classification (2021). arXiv:2104.07551.
- [6] H. Ismail Fawaz, B. Lucas, G. Forestier, C. Pelletier, D. Schmidt, J. Weber, G. Webb, L. Idoumghar, P.-A. Muller, F. Petitjean, InceptionTime: Finding AlexNet for time series classification, *Data Mining and Knowledge Discovery* 34 (2020) 1–27.
- [7] X. Zhang, Y. Gao, J. Lin, C.-T. Lu, TapNet: Multivariate Time Series Classification with Attentional Prototypical Network, *Proceedings of the AAAI Conference on Artificial Intelligence* 34 (04) (2020) 6845–6852.
- [8] K. Watanabe, A. Holobar, M. Kouzaki, M. Ogawa, H. Akima, T. Moritani, Age-related changes in motor unit firing pattern of vastus lateralis muscle during low-moderate contraction, *AGE* 38 (06 2016).
- [9] H. A. Dau, E. Keogh, K. Kamgar, C.-C. M. Yeh, Y. Zhu, S. Gharghabi, C. A. Ratanamahatana, Yanping, B. Hu, N. Begum, A. Bagnall, A. Mueen, G. Batista, Hexagon-ML, The UCR Time Series Classification Archive, [https://www.cs.ucr.edu/~eamonn/time\\_series\\_data\\_2018/](https://www.cs.ucr.edu/~eamonn/time_series_data_2018/) (October 2018).
- [10] M. Divjak, G. Sedej, N. Murks, M. Geržević, U. Marusic, R. Pišot, B. Šimunič, A. Holobar, Inter-Person Differences in Isometric Coactivations of Triceps Surae and Tibialis Anterior Decrease in Young, but Not in Older Adults After 14 Days of Bed Rest, *Frontiers in Physiology* 12 (2022).
- [11] A. Holobar, D. Zazula, Multichannel Blind Source Separation Using Convolution Kernel Compensation, *IEEE Transactions on Signal Processing* 55 (9) (2007) 4487–4496.
- [12] L. Liu, E. A. Clancy, P. Bonato, Calculation of Surface Electromyogram Discharge Rate, in: 2013 39th Annual Northeast Bioengineering Conference, 2013, pp. 187–188.