

**UPRAVLJANJE SA VIŠE STEPENI SLOBODE PRIMENOM TEHNIKA MAŠINSKOG UČENJA****CONTROL OF MULTIPLE DEGREES OF FREEDOM USING MACHINE LEARNING TECHNIQUES**

Aleksandra Paskaš, *Fakultet tehničkih nauka, Novi Sad*

**Oblast – BIOMEDICINSKO INŽENJERSTVO**

**Kratak sadržaj** – U ovom radu predstavljeno je upravljanje mioelektričnom protezom šake koje podrazumeva klasifikaciju 9 pokreta šake na osnovu ulaznih EMG signala zabeleženih sa četiri mišića podlaktice. Klasifikacioni algoritmi mašinskog učenja koji su razmatrani u ovom radu su LDA, SVM i ANN. Mere uspešnosti upotrebljene u cilju analize performansi klasifikatora su tačnost, osetljivost, specifičnost i preciznost.

**Ključne reči:** Mioelektrične proteze, Prepoznavanje obrazaca, Mašinsko učenje, LDA, SVM, ANN

**Abstract** – In this paper, the control of a myoelectric hand prosthesis is presented, which involves the classification of 9 hand movements based on input EMG signals collected from four forearm muscles. The machine learning classification algorithms discussed in this paper are LDA, SVM and ANN. The metrics used for evaluating classifiers performance are accuracy, recall, specificity and precision.

**Keywords:** Myoelectric prostheses, Pattern recognition, Machine learning, LDA, SVM, ANN

**1. UVOD**

Odsustvo ekstremiteta ili nekog njegovog dela može biti urođeno ili stečeno amputacijom i u velikoj meri se odražava na kvalitet života pojedinca. Zadatak proteza gornjih ekstremiteta jeste ponovno uspostavljanje ili poboljšanje preostalih manipulativnih funkcija [1].

Sistem proteze gornjeg ekstremiteta može se posmatrati sa dve tačke gledišta: mehatronički dizajn sistema i upravljanje sistemom.

Mehatronika sistema obuhvata mehaničke i elektronske komponente neophodne za rad. Upravljanje sistemom podrazumava kontrolne strategije i algoritme koji se primenjuju za prilagođavanje funkcije sistema u cilju ostvarivanja adekvatne interakcije čoveka i mašine.

Upravljanje protezom se ostvaruje protokom signala. Kontrolna jedinica unutar soketa prima ulazne signale od korisnika, koji oslikavaju pokret koji korisnik namerava da izvrši, i prevodi ih u komande za pokretanje uređaja. Proteze kontrolisane EMG signalima nazivaju se mioelektrične proteze (engl. *myoelectric prostheses*) [2].

**NAPOMENA:**

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Nikola Jorgovanović, red. prof.

**2. PREPOZNAVANJE OBRAZACA MIŠIĆNE KOAKTIVACIJE**

Potrebe korisnika za intuitivnijom i prirodnijom kontrolom većeg broja stepeni slobode dovele su do razvoja novih strategija upravljanja zasnovanih na prepoznavanju obrazaca mišićne koaktivacije (engl. *Pattern recognition-based myoelectric control*). Ove strategije se temelje na zapažanju da svaki prirodan pokret karakteriše specifičan obrazac aktivacije mišića. Prepoznavanje obrazaca mišićne aktivacije na osnovu EMG signala zabeleženih sa mišića preostalog dela ruke i identifikacija pokreta koji korisnik namerava da izvede vrši se primenom tehnika mašinskog učenja (engl. *Machine Learning, ML*) [3].

Efikasnost strategija upravljanja ovog tipa u potpunosti zavisi od odabira i izdvajanja obeležja. Nakon akvizicije ulaznih EMG signala i njihove digitalne obrade, sledeći korak je izdvajanje obeležja, a vektor obeležja se zatim dovodi na ulaz algoritma mašinskog učenja koji na svom izlazu daje upravljačku komandu. Obeležja reprezentuju sadržaj informacija u sirovim EMG signalim u formi koja je mnogo pogodnija kada je reč o upravljanju mioelektričnim protezama.

Na osnovu domena u kom se određuju, obeležja EMG signala se mogu grupisati u tri kategorije: obeležja u vremenskom, obeležja u frekvencijskom i obeležja u vremensko – frekvencijskom domenu [4]. Postupku izdvajanja obeležja prethodi postupak segmentacije podataka. Dužina segmenta tj. prozora određuje veličinu uzorka EMG signala nad kojim se vrši izdvajanje obeležja. Prozor se kontinuirano pomera u vremenu i na taj način je omogućeno neprekidno formiranje novih uzoraka.

Definisani segment se primenjuje na sve EMG kanale istovremeno, pa se tako na nivou svakog prozora skup obeležja izdvaja na svakom kanalu koji se koristi za snimanje, čime se dobija  $L$  – dimenzionalni vektor obeležja, pri čemu je  $L$  broj obeležja pomnožen sa brojem kanala [5]. Algoritmi mašinskog učenja koji se koriste za upravljanje mioelektričnim protezama se dele na klasifikacione i regresione [3].

Prednosti ovakvog načina upravljanja, u odnosu na strategije direktnog upravljanja, su u tome što se eliminiše potreba za preusmeravanjem kontrole između različitih stepeni slobode izvođenjem kokontrakcija ili aktiviranjem eksternog prekidača, a moguće je ostvariti i simultanu kontrolu više stepeni slobode proteze. Pored toga,


korisnici ne moraju da prolaze kroz naporan proces učenja individualnih mišićnih kontrakcija [3].

### 3. EKSPERIMENT: KLASIFIKACIJA POKRETA ŠAKE

Eksperiment podrazumeva klasifikaciju pokreta šake u jednu od sledećih devet klasa: pronacija podlaktice, fleksija šake, zatvaranje šake, abdukcija šake, supinacija podlaktice, ekstenzija šake, otvaranje šake, adukcija šake i stanje kada nema pokreta. Klasifikatori upotrebljeni za rešavanje opisanog problema su: LDA (engl. *Linear Discriminant Analysis*), mašina na bazi vektora nosača (engl. *Support Vector Machine - SVM*) i klasifikator zasnovan na veštačkim neuralnim mrežama (engl. *Artificial Neural Networks - ANN*).

#### 3.1. Akvizicija EMG signala

Za akviziciju EMG signala korišćen je SMARTING uređaj. Pojačanje ovog uređaja iznosi 24. Frekvencija odabiranja postavljena je na 500 Hz. U ovom eksperimentu, akvizicija EMG signala je vršena sa četiri kanala, koji su postavljeni na mišiće *flexor carpi ulnaris*, *extensor carpi ulnaris*, *flexor carpi radialis* i *extensor carpi radialis*.



Slika 1. Sekvenca pokreta šake

Tokom eksperimenta ispitanik je sedeo ispred monitora i od njega je zahtevano da izvrši devet pokreta šake, uključujući i stanje kada je šaka opuštena, redosledom koji je prikazan na slici 1. Ispitaniku se zadaje vizuelna komanda koji pokret je potrebno izvršiti. Izvršavanje jedne sekvence od devet pokreta podrazumeva da ispitanik izvede svaki od pokreta i zadrži taj pokret 4 s. Nakon svakog pokreta sledi odmor od 4 s. Dakle, ukupno trajanje jedne sekvence pokreta iznosi 76 s.

Obeležja za stanje kada je ruka opuštena, izdvajana su iz dela signala između 68 s i 72 s. Nakon izvršenih 9 sekvenci pokreta, pravljena je duža pauza kako bi se minimizovao efekat zamora mišića na kvalitet zabeleženih EMG signala. Postupak je ponovljen 6 puta.

Digitalna obrada EMG signala uključuje potiskivanje jednosmerne komponente i filtriranje Batervartovim filtrom propusnikom opsega desetog stepena, pri čemu je donja granična učestanost postavljena na 10 Hz, a gornja na 240 Hz.

#### 3.2. Formiranje baze podataka

Formiranje baze podataka podrazumeva izdvajanje obeležja iz snimljenih EMG signala. Kako bi se zadovoljio uslov koji nameće upravljanje u realnom vremenu, obeležja su izdvajana na nivou vremenskih prozora u trajanju od 250 ms, pri čemu je međusobno preklapanje dva susedna prozora 50%.

Prozori unutar kojih klasa pokreta nije jedinstvena, jer obuhvataju prelazak iz jednog pokreta u drugi, nisu analizirani. Jedan prozor predstavlja jedan uzorak.

Obeležja koja su upotrebljena u ovom eksperimentu su: srednja apsolutna vrednost (engl. *Mean absolute value, MAV*), koren srednjih kvadrata (engl. *Root mean square, RMS*), kumulativna dužina signala (engl. *Waveform length, WL*), *Zero crossing rate* i srednja frekvencija (engl. *Mean frequency, MNF*). Dakle, svaki uzorak je opisan sa 5 obeležja izdvajanih sa četiri merna kanala. Na ovaj način formirana je baza podataka koju čini 13516 uzorka opisanih sa 21 obeležjem. Obeležje *class* se izdvaja i predstavlja izlaznu promenljivu, dok se sva ostala obeležja smatraju ulaznim. Sva ulazna obeležja su numeričkog tipa. Baza podataka je podeljena na skup za obuku i test skup. U skupu za testiranje nalazi se 1352 uzorka što je 10% od ukupnog broja uzoraka. Obeležje *class* je predstavljeno numeričkim vrednostima od 0 do 8, pri čemu svaka vrednost oslikava jedan tip pokreta. Broj uzoraka po klasama nije jednak i istaknut je u Tabeli 1.

Tabela 1. Klase pokreta i broj uzoraka u njima

Klasa		Broj uzoraka	
Oznaka	Tip pokreta	Skup za obuku	Test skup
0	Odmor	1084	120
1	Pronacija podlaktice	1335	148
2	Fleksija šake	1392	155
3	Zatvaranje šake	1394	155
4	Abdukcija šake	1389	154
5	Supinacija podlaktice	1391	155
6	Ekstenzija šake	1390	155
7	Otvoravanje šake	1400	156
8	Adukcija šake	1389	154

#### 3.3. Performanse klasifikacionih algoritama

Svaki klasifikator poseduje određene parametre tzv. hiperparametri, koje je potrebno definisati pre obuke klasifikatora [6]. Za određivanje optimalnih vrednosti hiperparametara, upotrebljena je metoda unakrsne (*cross*) validacije sa 10 podskupova, pri čemu je kao mera uspešnosti analizirana tačnost klasifikatora za određenu kombinaciju hiperparametara. Nakon odabira hiperparametara klasifikator je obučen nad celim skupom za obuku, a nakon toga je testiran nad skupom za testiranje.

Procena performansi klasifikatora zasniva se na poređenju predviđenih i stvarnih labela klase. Kao sredstvo za uporedni prikaz usklađenosti između predviđenih i stvarnih oznaka klase koristi se matrica konfuzije. To je kvadratna matrica dimenzija jednakih broju klasa. Vrste unutar matrice konfuzije oslikavaju stvarne, a kolone predviđene vrednosti labela. Ispravno klasifikovani uzorci smešteni su na glavnoj dijagonali. Mere uspešnosti klasifikatora koje su razmatrane u ovom radu su tačnost,

osetljivost, specifičnost i preciznost i određene su na osnovu matrice konfuzije. Tačnost klasifikatora oslikava udeo ispravno klasifikovanih uzoraka u odnosu na sve dostupne uzorke. Preciznost je udeo uzoraka koji su dodeljeni određenoj klasi i zaista joj pripadaju. Osetljivost predstavlja udeo uzoraka iz određene klase koje klasifikator može da prepozna. Specifičnost je udeo uzoraka koje klasifikator nije dodelio određenoj klasi i zaista joj klasi ne pripadaju [6].

### 3.3.1. LDA (engl. *Linear Discriminant Analysis*)

Za LDA je karakteristično da se koristi i kao algoritam za redukciju dimenzionalnosti i kao klasifikator [6]. Hiperparametri ovog algoritma su dimenzije novog prostora obeležja dobijenog nakon redukcije dimenzionalnost i metoda koja se koristi za dobijanje karakterističnih vrednosti i karakterističnih vektora kovarijansne matrice [7]. Kombinacija hiperparametara koja je dala najveću tačnosti podrazumeva da je novi prostor obeležja dvodimenzionalan, a usvojeni metod je *svd* (engl. *Singular value decomposition*).

Tabela 2. *Mere uspešnosti LDA klasifikatora po klasama*

Klasa	Tačnost	Osetljivost	Specifičnost	Preciznost
1	0.850	0.459	0.898	0.356
2	0.915	0.574	0.959	0.645
3	0.851	0.439	0.905	0.374
4	0.921	0.649	0.956	0.654
5	0.882	0.574	0.921	0.486
6	0.896	0.490	0.949	0.555
7	0.907	0.365	0.978	0.687
8	0.921	0.649	0.956	0.654
0	0.945	0.742	0.965	0.674

U Tabeli 2. su istaknute mere uspešnosti po klasama i može se primetiti da LDA klasifikator ima najveću tačnost i osetljivost za klasu koja odgovara stanju mirovanja, dok je specifičnost i preciznost najbolja za pokret otvaranja šake.

### 3.3.2. Mašina na bazi vektora nosača (engl. *Support Vector Machine*)

Hiperparametri SVM klasifikatora su regularizacioni parametar (*C*) kojim se definiše ukupna tolerancija na grešku klasifikacije, kernel i s obzirom na to je reč o višeklasnom problemu potrebno je definisati pristup koji će se koristiti za razdvajanje klasa [6]. Usvojeni hiperparametri su: vrednost regularizacionog parametra jednaka 15, *rbf* kernel (engl. *Radial basis function*) i pristup svaki protiv svakog (engl. *one vs. one - ovo*) koji podrazumeva da se uzorak dodeljuje klasi koja je najviše puta ostvarila bolji uspeh u nadmetanju klasifikatora po parovima [6].

U Tabeli 3. prikazane su mere uspešnosti SVM klasifikatora po klasama. Može se primetiti, po svim merama uspešnosti, da je SVM najbolje klasifikovao uzorke iz klase koja odgovara stanju mirovanja. Što se

tiče pokreta, klasifikator je ostvario najveću tačnost, osetljivost i preciznost u slučaju uzoraka iz klase adukcija šake, dok je specifičnost klasifikatora najveća za pokret otvaranja šake. Niske vrednosti svih mera uspešnosti zapažaju se kod klasa koje odgovaraju pokretima pronacije podlaktice i zatvaranja šake.

Tabela 3. *Mere uspešnosti SVM klasifikatora po klasama*

Klasa	Tačnost	Osetljivost	Specifičnost	Preciznost
1	0.896	0.520	0.943	0.527
2	0.930	0.697	0.960	0.697
3	0.897	0.548	0.942	0.552
4	0.933	0.766	0.954	0.682
5	0.919	0.677	0.951	0.640
6	0.929	0.664	0.963	0.701
7	0.922	0.506	0.977	0.738
8	0.944	0.779	0.966	0.745
0	0.977	0.975	0.977	0.807

### 3.3.3. Veštačke neuronske mreže (engl. *Artificial Neural Networks, ANN*)

Veštačke neuronske mreže su složeni računarski sistemi inspirisani načinom funkcionisanja i strukturom bioloških neuralnih mreža. Formiraju ih veštački neuroni raspoređeni u slojeve. Postoje tri hiperparametra koje je potrebno precizirati kod ANN, i to su arhitektura mreže tj. broj i veličina skrivenih slojeva, optimizacioni algoritam za ažuriranje parametara mreže i maksimalan broj epoha za obuku [6]. Najveća tačnost ostvarena je u slučaju kada se koristi jedan skriveni sloj sa 25 neurona, *lbfgs* (engl. *Limited-memory Broyden-Fletcher-Goldfarb-Shanno*) je optimizacioni algoritam, a maksimalan broj epoha za obuku je 300 i to su vrednosti hiperparametara koje su usvojene. Mere uspešnosti ovog klasifikatora po klasama date su u Tabeli 4.

Tabela 4. *Mere uspešnosti ANN klasifikatora po klasama*

Klasa	Tačnost	Osetljivost	Specifičnost	Preciznost
1	0.888	0.500	0.936	0.490
2	0.925	0.645	0.961	0.680
3	0.900	0.523	0.949	0.570
4	0.932	0.773	0.952	0.676
5	0.907	0.697	0.935	0.581
6	0.922	0.593	0.964	0.681
7	0.910	0.468	0.968	0.658
8	0.945	0.773	0.967	0.753
0	0.978	0.983	0.977	0.808

Na osnovu rezultata iz Tabele 4. primećuje se da, kao i SVM klasifikator, ANN ima najviše uspeha za klasu koja odgovara stanju mirovanja dok se niske vrednosti svih

mera uspešnosti beleže za pokrete pronacija podlaktice i zatvaranje šake.

#### 4. ZAKLJUČAK

Poređenje performansi klasifikatora izvršeno je na osnovu prosečne tačnosti koju oni ostvaruju i vremena koje je potrebno da se algoritam izvrši. Prilikom odabira klasifikatora, pored uspešnosti koju on ostvaruje, veoma bitan faktor je složenost algoritma koja se reprezentuje kroz vreme potrebno da se algoritam izvrši.

Tabela 5. Prosečna tačnost i vreme potrebno za izvršavanje LDA, SVM i ANN algoritama

	LDA	SVM	ANN
Prosečna tačnost	0.899	0.928	0.923
Vreme [s]	0.063	8.152	15.408

Analizom rezultata prikazanih u Tabeli 5. uočava se da su sva tri klasifikatora ostvarila veoma visoku tačnost. Može se primetiti da ANN klasifikator nije dobar izbor za rešavanje predstavljenog problema jer je za izvršavanje ovog algoritma, zbog njegove složenosti, potrebno značajno više vremena u odnosu na ostale razmatrane klasifikatore, a prosečna tačnost je niža u odnosu na SVM klasifikator. LDA klasifikator je ostvario najmanju, ali i dalje uporedivu prosečnu tačnost, pri čemu mu veoma kratko vreme izvršavanja ide u prilog. Najbolju tačnost ostvario je SVM klasifikator. Prema tome, može se zaključiti da SVM i LDA predstavljaju dobre kandidate za rešavanje opisanog klasifikacionog problema. Koji od ta dva klasifikatora će biti odabran zavisi od načina na koji je potrebno ostvariti kompromis između tačnosti i složenosti ML algoritma.

#### 5. LITERATURA

[1] F. Mereu, F. Leone, C. Gentile, F. Cordella, E. Gruppioni, and L. Zollo, "Control Strategies and Performance Assessment of Upper-Limb TMR Prostheses: A Review," *Sensors*, Vol. 21, no. 6, p. 1953, Mar. 2021.

[2] A. Marinelli *et al.*, "Active upper limb prostheses: a review on current state and upcoming breakthroughs", *Progress in Biomedical Engineering*, Vol. 5, no. 1, p. 012001, Jan. 2023.

[3] M. Legrand, "Upper limb prostheses control based on user's body compensations," *theses.hal.science*, Mar. 2021.


[4] M. Hakonen, H. Piitulainen, and A. Visala, "Current state of digital signal processing in myoelectric interfaces and related applications," *Biomedical Signal Processing and Control*, Vol. 18, pp. 334–359, Apr. 2015.

[5] G. Li, "Electromyography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses," *Advances in Applied Electromyography*, Aug. 2011.

[6] Tijana Nosek, Branko Brkljač, Danica Despotović, Milan Sečujski, Tatjana Lončar-Turukalo, "Praktikum iz mašinskog učenja", *Univerzitet u Novom Sadu*, 2020.

[7] Yang, Li, and Abdallah Shami. "On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice." *Neurocomputing*, Vol. 415, pp. 295–316, Nov. 2020.

#### Kratka biografija:



**Aleksandra Paskaš** rođena je u Novom Sadu 1998. god. Master rad na Fakultetu tehničkih nauka iz oblasti Biomedicinsko inženjerstvo – Upravljački sistemi u biomedicinskom inženjerstvu odbranila je 2024.god.  
kontakt: paskasaleksandra@gmail.com