

KLASIFIKACIJA POKRETA ŠAKE NA OSNOVU EMG SIGNALA HAND GESTURE CLASSIFICATION BASED ON EMG SIGNALS

Jelena Radmino, *Fakultet tehničkih nauka, Novi Sad*

Oblast – BIOMEDICINSKO INŽENJERSTVO

Kratak sadržaj – U ovom radu prikazan je postupak obrade EMG signala i njihove klasifikacije u cilju određivanja pokreta šake. Korišćeni su klasifikatori na bazi k najблиžih suseda, vektora nosača i linearna diskriminantna analiza. Najbolje performanse ima klasifikator na bazi k najблиžih suseda. Rezultati pokazuju potrebu kvalitetnijeg oblika normalizacije signala, u cilju poboljšanja klasifikacije. Takođe bi bilo poželjno obučiti neuralnu mrežu pa ispitati njene performanse.

Ključne reči: EMG signali, obrada podataka, klasifikacija

Abstract – This paper presents EMG signals processing and classification of hand gesture. Used classifiers are based on k nearest neighbors method, support vector machine method and linear discriminant analysis. The classifier based on k nearest neighbors has the best performance. Results shows need for a better form of signal normalization, in order to improve classification. Also, it would be a good to train a neural network and test its performance.

Keywords: EMG signals, data processing, classification

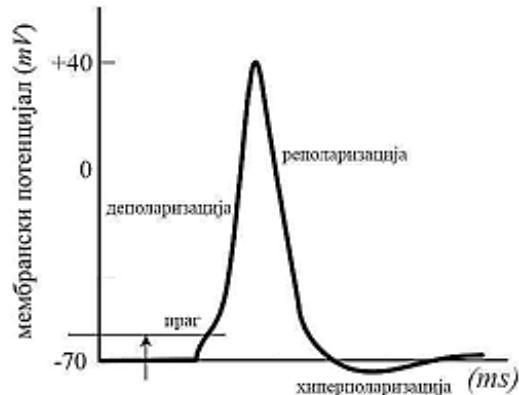
1. UVOD

Mišić predstavlja meko tkivo, sačinjeno od posebnih mišićnih vlakana koja poseduju sposobnost kontrakovanja čime se menja dužina mišića. Osnovna funkcionalna jedinica mišića je motorna jedinica koja se sastoji od α-motoneurona i mišićnog vlakna. Da bi došlo do kontrakcije mišića potreban je impuls od strane motoneurona. Na sinapsi dva motoneurona, na delu membrane motoneurona nastaje akcioni potencijal (slika 1.) koji se dalje širi celom membrnom.

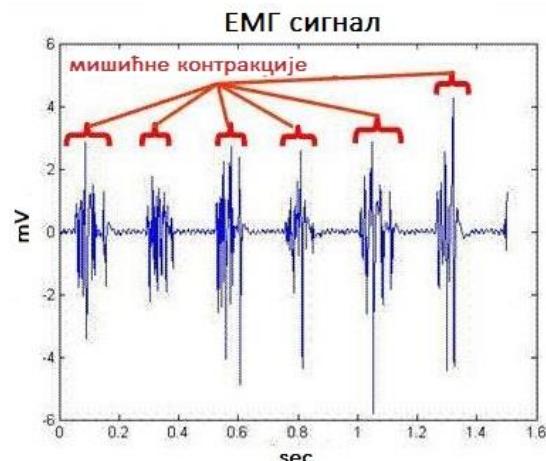
Metoda beleženja električne aktivnosti koja nastaje u mišićima jeste elektromiografija (EMG). EMG signal predstavlja detektovanu razliku napona na koži koja nastaje usled provodnosti električnih impuls generisanih i simultano sprovedenih velikim brojem vlakana. EMG signal (slika 2.) je kompleksan signal sa pikovima koji imaju i negativne i pozitivne komponente, a amplitude zavise od položaja merne površinske elektrode.

2. BAZA PODATAKA

Podatke za klasifikaciju čine obrađeni EMG signali snimljeni pomoću MYO Thalmic narukvice. 36 osoba je izvodiло seriju statičnih pokreta šake, gde je svaka osoba izvo-



Slika 1. Akcioni potencijal



Slika 2. EMG signal

dila po 2 serije. Jedna serija se sastoji od 12-14 pokreta, tj. 6-7 osnovnih pokreta (slika 3.) izvedenih dva puta:

- 1) Šaka u mirovanju (eng. Hand at rest)
- 2) Šaka stegnuta u pesnicu (eng. Hand clenched in a fist)
- 3) Fleksija ručnog zgloba (eng. Wrist flexion)
- 4) Ekstenzija ručnog zgloba (eng. Wrist extension)
- 5) Radijalna devijacija (eng. Radial deviation)
- 6) Ulnarna devijacija (eng. Ulnar deviation)
- 7) Raširena šaka (eng. Extended palm) – ovaj pokret nisu izvodile sve osobe

Svaki pokret je izvođen 3 sekunde sa pauzom od 3 sekunde između pokreta.

Među podacima su postojali i neoznačeni podaci koji su izbačeni iz validacije jer mogu značajno uticati na performanse klasifikatora.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Darko Stanišić, vanred. prof.



Slika 3. Osnovni pokreti za MYO Thalmic narukvicu

Validacija je odrađena na 2 skupa podataka: prvi skup sadrži originalne signale, a drugi normalizovane signale. Normalizacija je odrađena u cilju smanjenja uticaja karakteristika samog subjekta na dobijene vrednosti signala. Izvlačenje obeležja je podrazumevalo računanje RMS i MP signala za svaki pokret subjekta.

2.1. RMS i MP signali

RMS (eng. *Root Mean Square*) signal predstavlja signal kvadratnih korena usrednjenoj kvadrata. Vrednosti RMS signala su izračunate nad određenim prozorom vrednosti signala sa 400 odbiraka i međusobnim preklapanjem prozora nad 200 odbiraka. Svaka od vrednosti RMS signala se računa pomoću formule (1), gde je i – i -ti element RMS signala, a N – dužina prozora.

$$x_i = \sqrt{\frac{1}{N}(x_1^2 + x_2^2 + \dots + x_N^2)} \quad (1)$$

Pod pretpostavkom da je postojala zakasnela reakcija prilikom izvođenja pokreta, iz dalje analize i klasifikacije izbačen je prvi odbirak RMS signala koji predstavlja prvih ~200ms zabeleženog pokreta.

Za razliku od RMS signala koji se računa za svaki kanal, MP (eng. *Mean Power*) signal je samo jedan i računa se na osnovu 8 RMS signala. Vrednosti MP signala predstavljaju usrednjene kvadrirane vrednosti svih RMS signala za dati pokret.

Tabela 1. Zastupljenost klase

Klase	Zastupljenost klase
1 – šaka u mirovanju	16.62%
2 – šaka stegnuta u pesnicu	16.05%
3 – fleksija ručnog zglobo	16.43%
4 – ekstenzija ručnog zglobo	16.57%
5 – radijalna devijacija	16.65%
6 – ulnarna devijacija	16.75%
7 – raširena šaka	0.93%

2.2. Analiza podataka

Analizom podataka mogu se otkriti određene pravilnosti među podacima koje nisu očigledne, a mogu biti korisne. Analizirani su RMS i MP signali.

U tabeli 1 prikazan je procenat zastupljenosti klase 1-7. Približno jednak su zastupljene klase 1-6, dok je klasa 7 najmanje zastupljena što je u skladu sa činjenicom da taj pokret nisu izvodile sve osobe.

Kako su RMS i MP signali pozitivni tako im je i minimalna vrednost jednak 0. Upoređivanjem srednjih vrednosti MP signala uočava se najmanja vrednost za klasu 1 što je i logično pošto je šaka u mirovanju.

3. KLASIFIKACIJA POKRETA

Klasifikacija predstavlja proces pridruživanja objekta određenoj klasi, gde objekti u okviru iste klase imaju slične vrednosti obeležja.

U skupu za obuku klasa svakog uzorka je unapred poznata, dok je zadatak klasifikatora da prostop obeležja izdeli na klasne regije odlučivanja i kao izlaz vrati oznaku klase kojoj dati uzorak pripada.

Poredila se se 3 algoritma klasifikacije:

- Klasifikator na osnovu k najbližih suseda (eng. *k-Nearest Neighbors* – kNN)
- Klasifikator na bazi vektora nosača (eng. *Support Vector Classifier* – SVC)
- Linearna diskriminantna analiza (eng. *Linear Discriminant Analysis* - LDA)

Performanse klasifikatora oslikavaju se na konfuzionu matricu koja je korišćena za izračunavanje tačnosti u skladu sa formulom (2).

$$\text{tačnost} = \frac{TP_0 + TP_1 + TP_2 + TP_3 + TP_4 + TP_5 + TP_6 + TP_7}{\sum_{i=0}^7 TP_i + \sum_{\substack{j,k=0 \\ j \neq k}}^7 FP_{jk}} \quad (2)$$

3.1. kNN klasifikator

kNN metod predstavlja metod klasifikacije novih uzoraka na osnovu sličnosti sa postojećim uzorcima iz skupa za obuku. Ova metoda pripada klasi algoritama sa kasnim učenjem jer se obrada uzorka odlaže sve dok ne pristigne novi zahtev za klasifikaciju nepoznatog uzorka.

Formirano je 60 kNN klasifikatora sa različitim kombinacijama parametara od kojih su se izdvojila po 4 najbolja za svaki skup podataka. Klasifikacija primenjenih skupova podataka je najbolja za metriku „Manhattan“, a broj najbližih suseda se razlikuje samo za skupove podataka (originalni – 100, normalizovani – 10).

3.2. Klasifikator na bazi vektora nosača

SVC konstruiše hiperravninu odlučivanja na osnovu kojih se vrši klasifikacija uzorka. Hiperravninu može biti više, od kojih se bira ona hiperravan kod koje su uzorci različitih klasa razdvojeni što je moguće većom prazninom (marginom).

Uzorci koje je potrebno klasifikovati dodeljuju se određenoj klasi u zavisnosti sa koje strane margine se nalaze.

Pošto se ovaj klasifikator uglavnom koristi za slučaj 2 klase, ako slučaj nije linearno razdvojiv može se odabrat nelinearan kernel i pristup odluke „ovo“ (eng. *One Versus One*) ili „ovr“ (eng. *One Versus Rest*)

Formirano je 160 SVC-a od kojih je izdvojeno po 3 najbolja za svaki skup podataka. Rezultati za svaki od 160 isprobanih klasifikatora se ne razlikuju po pitanju odabira pristupa odluke klasifikacije („ovo“ i „ovr“), ali je za dalju analizu odabran pristup „ovr“.

3.3. Linearna diskriminantna analiza

LDA metoda se može koristiti kao linearni klasifikator koji na osnovu linearne kombinacije obeležja odlučuje kojoj klasi pripada uzorak.

Svakoj klasi se pridružuje linearna diskriminantna funkcija koja uzima u obzir srednju vrednost, varijansu i apriornu verovatniću klase. Nepoznati uzorak se dodeljuje onoj klasi čija diskriminantna funkcija daje najveću vrednost za dati uzorak.

Formirano je 32 LDA klasifikatora od koji je izdvojeno po 2 najbolja za svaki skup podataka. Ovakav klasifikator ne pokazuje baš najbolje performanse usled nelinearnosti podataka za klasifikaciju.

4. REDUKCIJA DIMENZIONALNOSTI

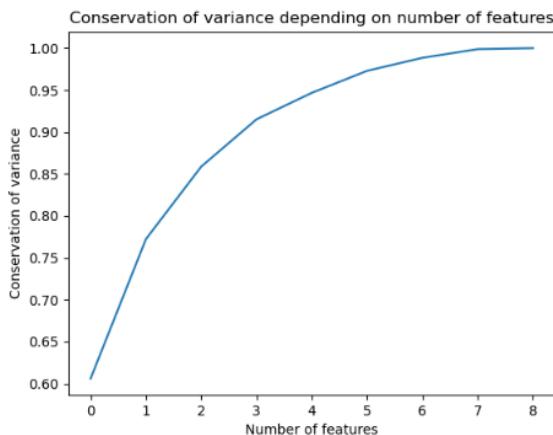
U cilju pojednostavljenja diskriminantne funkcije koja je u više dimenzionalnim prostorima kompleksna vrši se smanjenje broja obeležja.

Metoda koja je korišćena za redukciju dimenzionalnosti je PCA (eng. *Principal Component Analysis*) koja radi na principu izdvajanja obeležja tj. formiranja manjeg skupa novih obeležja kombinovanjem postojećih i to ne uzimajući u obzir klasnu pripadnost uzorka.

Ova metoda vrši rotaciju koordinatnog sistema tako što poravnava ose rotiranog sistema sa pravcima maksimalne varijanse.

Na slici 4. prikazana je očuvanost varijanse u zavisnosti od broja obeležja i može se uočiti da je varijansa očuvana preko 95 % za više od 5 obeležja.

Zarad bolje analize isprobani su najbolje pokazani klasifikatori na podacima sa redukcijom 1-8 obeležja.



Slika 4. Očuvanost varijanse u zavisnosti od broja obeležja

5. POREĐENJE REZULTATA

Za svaki od najbolje istaknutih klasifikatora primenjena je redukcija obeležja na osnovu kojih je vršena klasifikacija.

Izdvojeni su klasifikatori sa najvećom tačnošću, a poređenje tačnosti bez i sa redukcijom dimenzionalnosti prikazano je u tabeli 2.

Tabela 2. Poređenje tačnosti kNN, SVC i LDA klasifikatora bez i sa redukcijom dimenzionalnosti za oba skupa podataka

Spec. klasifikatora	Tačnost bez red. dim.	Tačnost sa red. dim.	Br. red. obeležja	Normaliz.
kNN: 5 krosval. k=1 „manhattan“ metrika	77.44%	76.79%	8	Ne
kNN: 5 krosval. k=1 „manhattan“ metrika	70.05%	76.19%	8	Da
kNN: 7 krosval. k=1 „manhattan“ metrika	77.31%	76.62%	8	Ne
kNN: 7 krosval. k=1 „manhattan“ metrika	70.43%	76.40%	8	Da
kNN: 10 krosval. k=1 „manhattan“ metrika	77.45%	76.97%	8	Ne
kNN: 10 krosval. k=10 „manhattan“ metrika	70.35%	75.85%	8	Da
kNN: 20 krosval. k=1 „manhattan“ metrika	77.55%	76.61%	8	Ne
kNN: 20 krosval. k=1 „manhattan“ metrika	70.47%	76.41%	8	Da
SVC: 10 krosval. „rbf“ kernel gamma=scale tol=0.01 „ovr“ odluka	73.36%	73.58%	8	Ne
SVC: 20 krosval. „rbf“ kernel gamma=scale tol=0.01 „ovr“ odluka	57.15%	72.45%	8	Da

SVC: 20 kroval. „poly“ kernel degree=2 gamma=scale tol=0.001 „ovr“ odluka	71.47%	66.22%	8	Ne
SVC: 20 kroval. „poly“ kernel degree=2 gamma=scale tol=0.001 „ovr“ odluka	51.55%	64.41%	8	Da
SVC: 20 kroval. „sigmoid“ kernel gamma=auto tol=0.001 „ovr“ odluka	64.17%	44.05%	8	Ne
SVC: 7 kroval. „sigmoid“ kernel gamma=scale tol=0.01 „ovr“ odluka	28.50%	42.40%	8	Da
LDA: 20 kroval. „svd“ solver tol=0.01	65.61%	65.35%		Ne
LDA: 20 kroval. „svd“ solver tol=0.01	64.60%	63.99%	8	Da
LDA: 7 kroval. „lsqr“ solver shrinkage=auto	65.68%	65.31%	8	Ne
LDA: 20 kroval. „lsqr“ solver shrinkage=None	64.60%	63.97%	8	Da

Poboljšanje tačnosti prilikom redukcije dimenzionalnosti kod normalizovanog skupa podataka uočava se kod kNN-a i SVC-a, dok kod originalnog skupa podataka, za sve klasifikatore, postoji obrnut efekat tj. blago slabljenje performansi.

Ako uporedimo rezultate klasifikatora u zavisnosti od tipa podataka (originalni i normalizovani), rezultati su bolji ukoliko se koristi originalni skup podataka (sa ili bez redukcije). kNN i LDA klasifikator daju najbolje rezultate za originalan skup podataka sa originalnim obeležjima (bez redukcije).

Poređenjem konfuzionih matrica na slici 5., između matriča A i B uočava se povećanje broja tačno klasifikovanih pokreta za maticu A. Čak je i klasa 7 uspešno klasifikovana sa minimalnim brojem pogrešno klasifikovanih.

Ukoliko se uporede matica B i C uočava se grupacija pogrešno klasifikovanih pokreta u matrići C za klase 1 (šaka u mirovanju) i 6 (ulnarna devijacija), dok je u matrići B ravnomerno raspoređeno među klasama.

Предиктована класа	Стварна класа						
	1	2	3	4	5	6	7
1	895	96	98	93	1	1	0
2	0	953	101	87	1	1	0
3	1	93	951	95	2	28	0
4	0	89	104	945	37	4	1
5	2	97	95	133	859	0	0
6	1	81	127	112	0	872	0
7	1	5	5	6	1	0	48

Предиктована класа	Стварна класа						
	1	2	3	4	5	6	7
1	906	64	61	51	56	18	28
2	16	903	65	59	59	14	27
3	19	59	895	55	59	49	34
4	14	69	53	890	100	20	34
5	12	67	55	93	914	15	30
6	14	57	89	58	55	885	35
7	3	4	2	4	2	2	49

Предиктована класа	Стварна класа						
	1	2	3	4	5	6	7
1	1177	2	5	0	0	0	0
2	292	815	22	0	2	12	0
3	301	14	796	1	6	52	0
4	287	1	0	826	58	8	0
5	295	3	3	70	813	2	0
6	286	6	92	21	0	788	0
7	17	0	0	4	1	19	25

Slika 5. Konfuzione matrice kNN klasifikatora sa najvećom tačnošću za originalna (A) i normalizovana obeležja (B) i SVC klasifikatora za originalna obeležja (C).

6. ZAKLJUČAK

Performanse klasifikatora – tačnost klasifikacije i konfuziona matrica, kao i upoređivanje rezultata za gore spomenute klasifikatore daju par bitnih informacija:

- Redukcija dimenzionalnosti u slučaju originalnog skupa podataka, i normalizacija negativno utiču na performanse klasifikatora
- Kod kNN-a, pogrešno klasifikovani pokreti su raspoređeni za sve klase, dok kod SVC-a i LDA najviše pogrešno klasifikovanih pokreta ima za klase 1 (šaka u mirovanju) i 6 (ulnarna devijacija)
- Najveću tačnost daje kNN klasifikator za originalan skup podataka (tačnost od 77.55%)

Normalizacija signala je odradena na osnovu EMG signala šake u mirovanju, ali može biti problematična zbog niskih vrednosti signala. Potrebno je odraditi eksperiment u kom bi subjekat vršio maksimalnu kontrakciju mišića i na osnovu koga bi se dalje radila normalizacija ostalih signala. Ovakav vid normalizacije bi verovatno pozitivno uticao na ishod klasifikacije.

Takođe, zbog same prirode baze podataka bilo bi poželjno obučiti neuralnu mrežu pa ispitati njene performanse.

Kratka biografija:



Jelena Radmilo rođena je u Novom Sadu 1998. god. Master rad na Fakultetu tehničkih nauka iz oblasti Biomedicinskog inženjerstva odbranila je 2023.god.

kontakt: jelenaradmilo@yahoo.com