

*Univerzitet u Beogradu
Elektrotehnički fakultet
Odsek za signale i sisteme*



Diplomski rad

Klasifikacija mentalnih aktivnosti korišćenjem parametara statističkih očekivanja višeg reda EEG signala

mentor: Mirjana Popović
student: Marko Jevremović 04/321

1. Uvod

Ovaj rad se bavi isključivo softverskom komponentom uređaja kategorisanih pod *Brain-Computer Interface* (BCI, nadalje u tekstu). BCI su sistemi koji omogućavaju komunikaciju čoveka sa nekim uređajem, i to direktnim očitavanjem i tumačenjem moždane aktivnosti. Na taj način periferni nervi i motorika (pokreti ruku, govor...) ne učestvuju u komunikacionom putu, što definiše i oblast primene ovakvih sistema: u medicini, za potrebe ljudi čiji su periferni nervni sistem i motorika oštećeni.

Uređaji koji spadaju pod BCI sisteme se razlikuju po načinu snimanja moždane aktivnosti i po upotrebi (tipu uređaja sa kojim se vrši komunikacija). Najčešći način akvizicije je snimanje električne aktivnosti mozga površinskim elektrodoma. Ovaj pristup je povoljan pre svega zato što je tehnika neinvazivna, sistemi su portabilni i jeftiniji za eksploraciju. Treba napomenuti da iako površinski EEG ima prednost u BCI sistemima, takođe nosi sa sobom i mnoge probleme od kojih neki još uvek nisu rešeni na zadovoljavajući način, ili nisu rešeni uopšte. Jedan od osnovnih problema površinskog snimanja EEG-a je velika snaga aditivnog šuma u merenjima. Taj problem se rešava ili ugradnjom elektroda, čime se prilazi izvoru signala i povećava odnos signal/šum, što nije uvek prihvatljivo rešenje, ili se rešava softverski prilikom obrade signala.

U ovom radu je korišćen poslednji pristup, gde je problem šuma ostavljen na softveru. Problem malog odnosa signal/šum je naglašen u uobičajenom pristupu modelovanja EEG signala. Naime, smatra se da je signal linearan i stacionaran stohastički proces (posmatrano u kraćem vremenskom intervalu) koji se može opisati gausovom raspodelom gustine verovatnoće. Za signal koji je modelovan na taj način usvajaju se parametri dobijeni primenom neke od tehnika za obradu linearnih signala, na osnovu kojih se zatim projektuju željeni klasifikatori koji utvrđuju postojanje jednog tipa moždane aktivnosti iz unapred usvojenog skupa istih. Jedan od pristupa je da se klasifikacija vrši na osnovu koeficijenata autoregresivnog modela signala. Drugi način je da se usvoji mali broj parametara koji na efikasan način mogu da opišu spektar signala. U oba ova pristupa aditivni šum je veoma bitan faktor koji utiče na vrednosti parametara.

Realno, signal je izrazito nestacionaran i nastaje sabiranjem odziva više desetina hiljada nelinearnih prekidačkih elemenata (kojima se mogu modelirati neuroni). Ignorisanjem te činjenice gube se i informacije koje signal nosi upravo u svojoj nelinearnosti. U ovom radu je korišćen set parametara predloženih u radu "*Classifying mental tasks based on features of higher-order statistics from EEG signals in brain-computer interface*"^[1]. Deo korišćenog seta parametara čine parametri dobijeni pomenutim linearnim tehnikama. Nelinearnost signala je modelovana korišćenjem statističkih momenata višeg reda. Naime, za signal modelovan Gausovom raspodelom statistički momenati neparnog reda (1,3,5...) su identički jednaki nuli, ali u slučaju kada signal nije gausovski proces, to ne važi. Treći momenat je definisan jednačinom:

$$C_{3x}(m,n) = E\{x(k)x(k+m)x(k+n)\}$$

Parametri su dobijeni iz bispektruma koji odgovara signalu C_{3x} , definisanom sa:

$$B_x(\omega_1, \omega_2) = \sum_{-\infty}^{\infty} \sum_{-\infty}^{\infty} C_{3x}(m, n) \cdot \exp[-j2\pi(m\omega_1 + n\omega_2)]$$

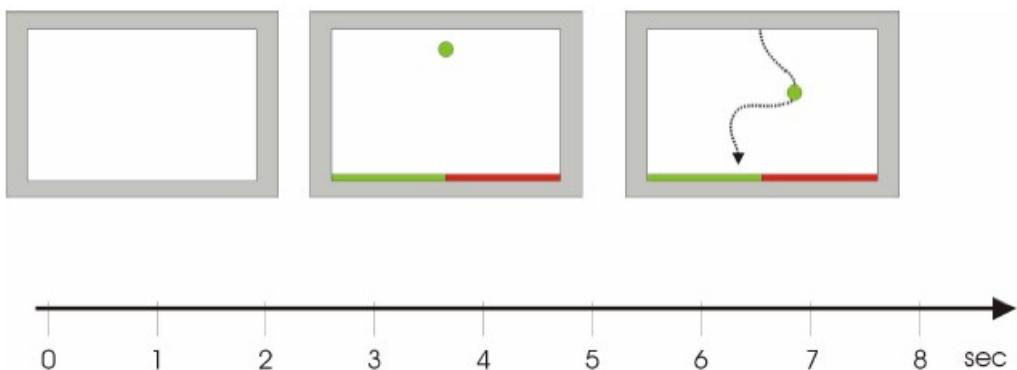
Na ovaj način u proces odlučivanja uvedene su dodatne informacije koje potiču od nelinearnosti signala. Zbog osobine belog gausovskog šuma da mu je statistički momenat trećeg reda jednak nuli, beli aditivni šum ne utiče na vrednosti ovih parametara. To je još jedna prednost ovog pristupa.

2. Eksperiment

Signali na kojima je vršeno obučavanje i testiranje klasifikatora su deo baze podataka korišćene u Gracovom BCI takmičenju 2003. Eksperiment za koji je projektovan ovaj klasifikator je označen sa IIIb u bazi podataka na zvaničnom sajtu takmičenja.

1. Opis eksperimenta

U eksperimentu je zahtevano od subjekta da na dati znak zamišljaju pokret leve, odnosno desne ruke. Eksperiment je izvođen sa fidbekom u realnom vremenu, koji unosi nestacionarnost u proces odlučivanja. Za fidbek korišćena je paradigma košare prikazana na slici 1.

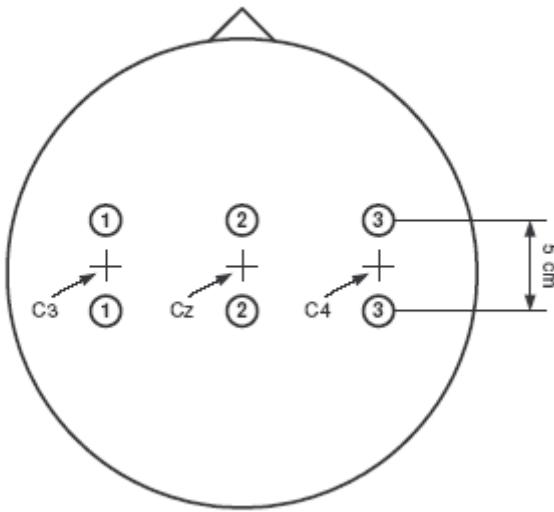


Sl.1. Izgled eksperimenta sa fidbekom

Subjekat je dobijao znak u trećoj sekundi, a zatim od četvrte do sedme sekunde pacijent upravlja zamišljanjem odgovarajućeg pokreta kuglicom na ekranu, koju mora da dovede na zadatu stranu.

Zapisи су uzeti sa elektroda C3 i C4 bipolarno (između odgovarajuće elektrode i Cz), kao što je prikazano na slici 2. Signali su semplovani na 125 Hz i filtrirani

između 0.5 i 30 Hz. Snimci su sažeti u zasebne baze podataka po subjektima i dati u GDF formatu.



Sl.2. pozicija elektroda

3. Analiza podataka

1. Ekstrakcija parametara za klasifikaciju

Za svaki kanal je računato 12 parametara predloženih u radu^[1]. Parametri su računati na prozoru dužine 256 odbiraka, za svaki odbirak vremena. Njih čine:

- 1) Četiri koeficijenta AR modela dobijenog rešavanjem Burgove jednačine
- 2) Četiri parametra dobijena iz spektra gustine snage signala (PSD)
 - i. Vršna vrednost PSD
 - ii. Frekvencija vršne vrednosti PSD
 - iii. Prvi momenat PSD
 - iv. Drugi momenat PSD
- 3) Četiri parametra dobijena iz bispektruma signala
 - i. Suma logaritama amplituda bispektruma

$$H_1 = \sum_{\omega_1, \omega_2 \in F} \log(|B_x(\omega_1, \omega_2)|)$$
 - ii. suma logaritama amplituda dijagonalnih elemenata

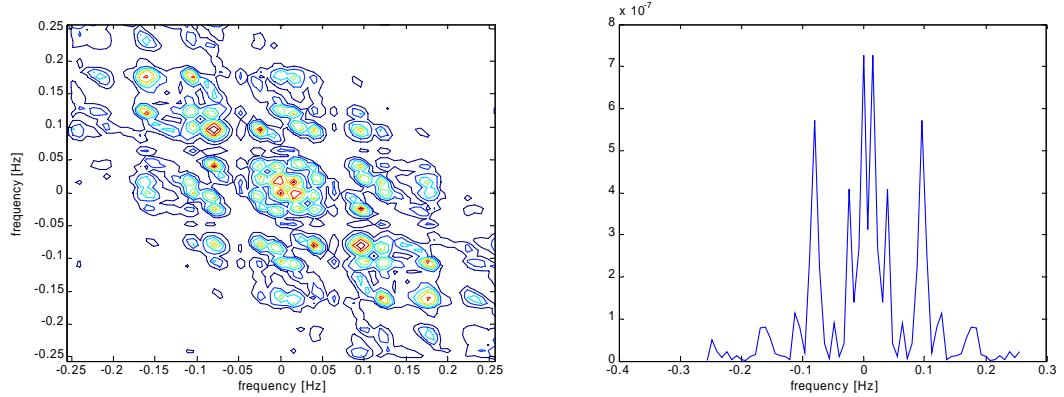
$$H_2 = \sum_{\omega \in F} \log(|B_x(\omega, \omega)|)$$
 - iii. prvi momenat amplituda dijagonalnih elemenata bispektruma

$$H_3 = \sum_{\omega \in F} k \cdot \log(|B_x(\omega, \omega)|)$$
 - iv. drugi momenat amplituda dijagonalnih elemenata bispektruma

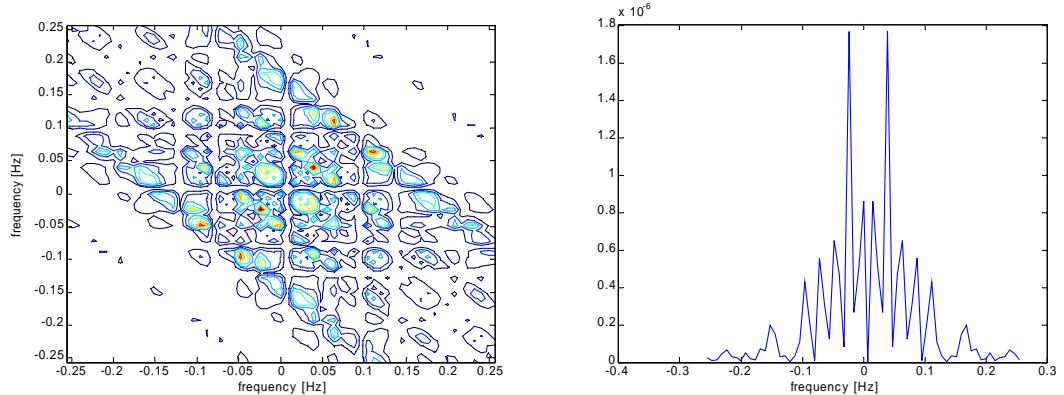
$$H_4 = \sum_{\omega \in F} (k - H_3)^2 \cdot \log(|B_x(\omega, \omega)|)$$

U gornjim formulama F je oblast frekvencija od interesa. Računanje trećeg statističkog momenta na ograničenom prozoru (od 256 elemenata) zahteva da se signal proširi nulama sa obe strane. Zbog toga opada pouzdanost računa kako pomeraji m i n rastu po apsolutnoj vrednosti. Zbog toga je neophodno uzeti u obzir samo podatke iz male oblasti centrirane oko nule bispektruma. Odlučeno je da ta oblast bude veličine 64x64 odbirka, što je 1/16 deo bispektruma.

Prednost koju unose poslednja četiri parametra može da se vidi sa narednih slika. Na slikama 3. i 4. se jasno vidi razlika između dve klase. Nažalost, relacija je samo jednostrana: kada postoji jasna mentalna aktivnost jednog tipa – bispektrum će imati odgovarajući oblik (u većem delu vremena), međutim pojava karakterističnog oblika bispektruma ne znači da postoji jasna mentalna aktivnost koja odgovara jednoj od traženih klasa.



Sl.3. Oblik bispektruma (levo) i dijagonalnog preseka (desno) prilikom zamišljanja pokreta desnom rukom

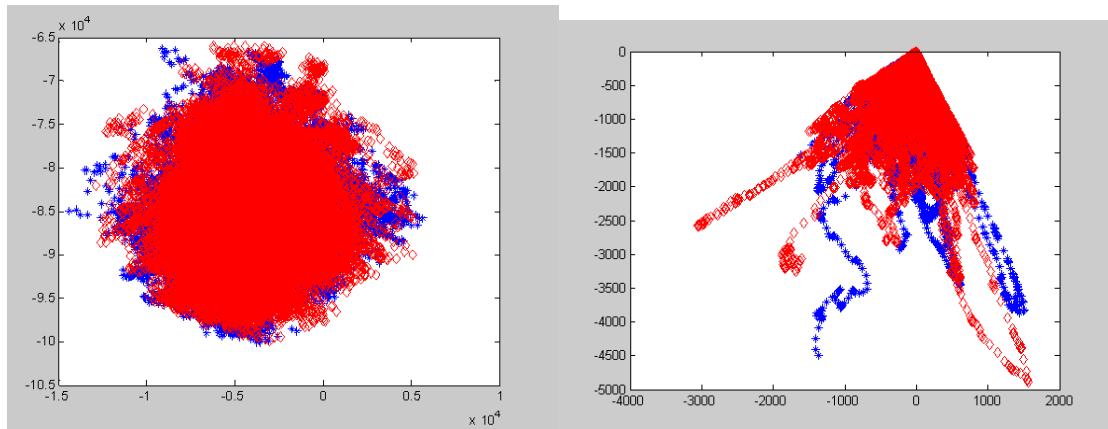


Sl.4. Oblik bispektruma (levo) i dijagonalnog preseka (desno) prilikom zamišljanja pokreta levom rukom

2. Analiza parametara

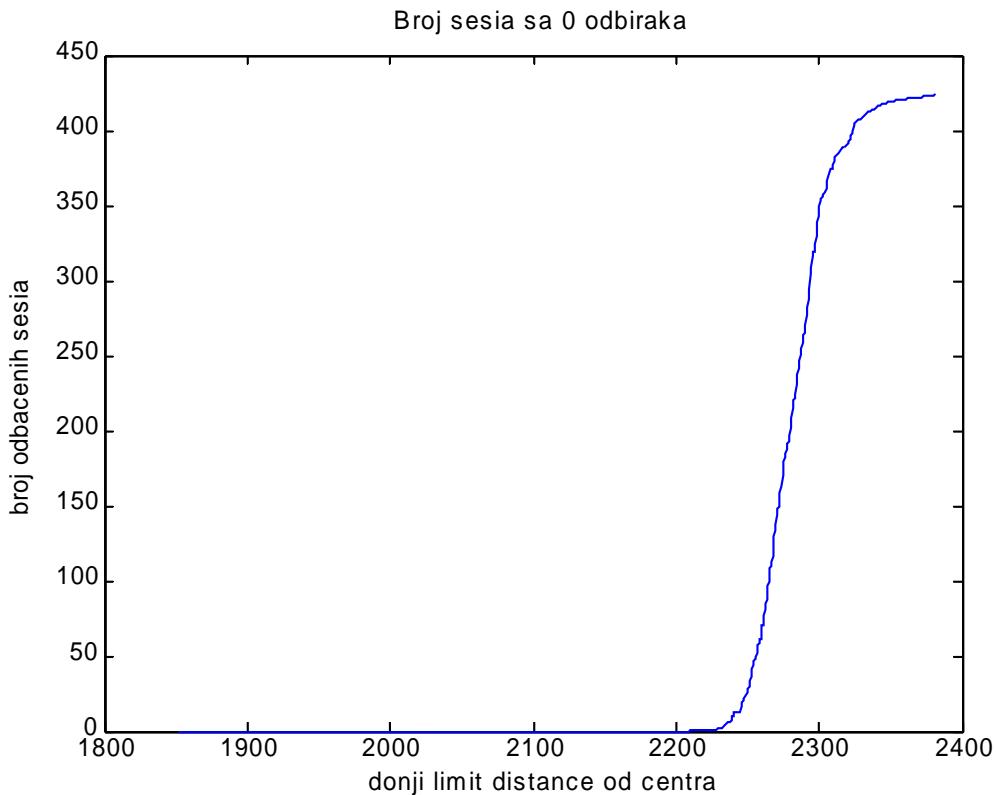
Broj podataka za projektovanje klasifikatora je nepraktično veliki. Takođe postavlja se i pitanje validnosti podataka. Postoji trenuci kada subjekt nije skoncentrisan na postavljeni zadatak. U prve 3 sekunde eksperimenta se to i ne traži od njega, a na samom kraju sesije subjekat se ne koncentriše jer je već završio postavljeni zadatak (loptica je na odgovarajućoj strani). Na slici 1 se vidi da se dešava da u periodu fidbeka subjekt ne uspeva da bude konstantno skoncentrisan na postavljeni zadatak, tako da se dešava da loptica kreće na pogrešnu stranu pre nego što stigne na traženo odredište. Skup za obučavanje se može redukovati uzimanjem odbiraka samo posle treće sekunde, ali ostali problemi koji su navedeni se ne mogu tako lako otkloniti, što ograničava mogućnost projektovanja ispravnog klasifikatora.

Znači, postoji veliki broj redundantnih podataka koje bi trebalo izbaciti iz procesa odlučivanja i obučavanja klasifikatora. Analizom vektora parametara za ceo skup jednog subjekta zaključeno je da se klase preklapaju u velikoj meri, i da je najveći broj odbiraka grupisan oko zajedničkog težišta celog skupa. Posmatranjem slike dobijene redukcijom oblika vidi se i da sa udaljenjem od težišta raste i mogućnost ispravne klasifikacije. Prepostavimo da se oko težišta okupljaju odbirci koji odgovaraju "pozadinskoj aktovnosti" (pojava je uočljivija na slici 5. desno), koje želimo da izbacimo.



Sl.5. redukcija oblika (levo) i drugi "pogled na klase" (desno)

Uklanjanjem odbiraka sa neke granične distance od težišta skupa bi dovelo do potpunog gubljenja podataka za pojedini sesije. Na slici 2 je prikazana zavisnost broja sesija za koje se gube sve informacije, uklanjanjem odbiraka iz sfere definisane u prostoru stanja skupa podataka, u funkciji distance od težišta. Broj sesija koje su na raspolaganju je 460, a na slici 3 je prikazano kako raste broj "praznih" sesija sa povećanjem granice odbacivanja odbiraka.



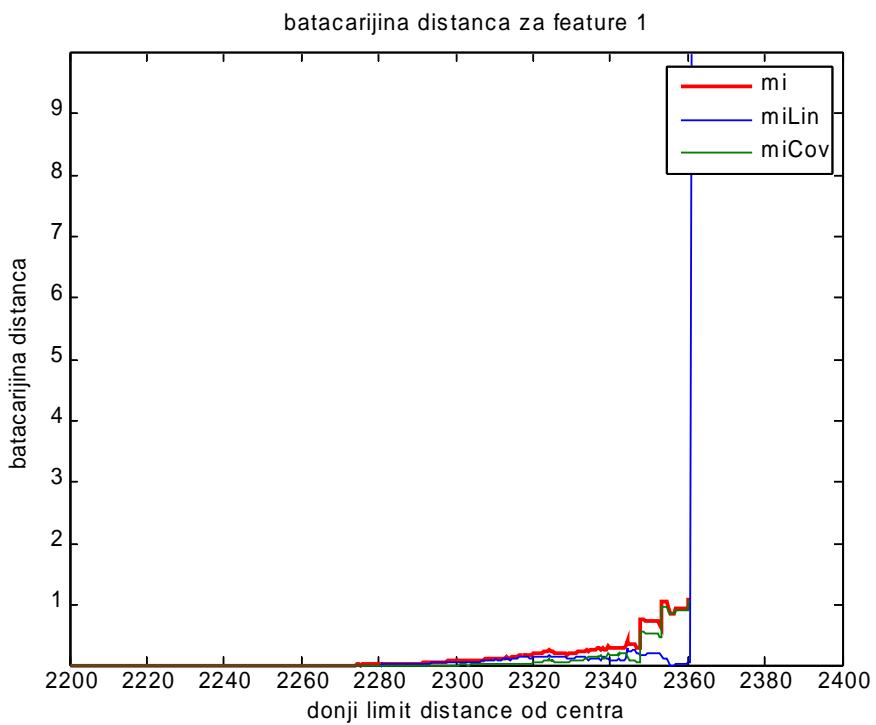
Sl.6. Broj sesija sa 0 odbiraka u redukovanim skupovima

Druga bitna informacija je kako redukcija podataka utiče na separabilnost klasa. Sledi niz grafika na kojima je prikazana Batačarijina distanca klasa za svaki od redukovanih skupova. Svaka slika odgovara jednoj komponenti vektora. Batačarijina distanca se računa po formuli:

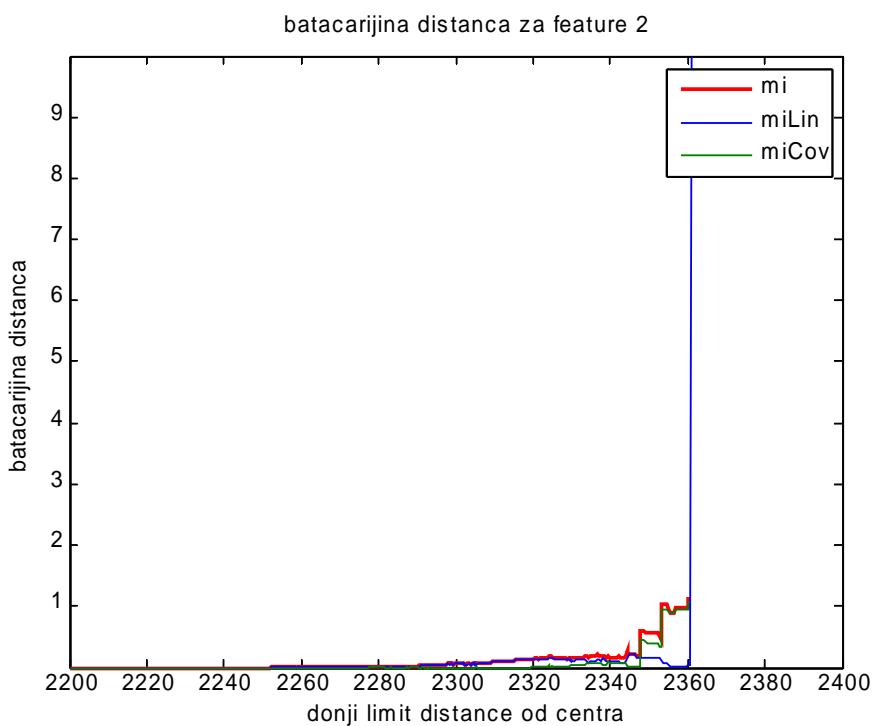
$$\mu = \frac{1}{8}(\mathbf{M}_2 - \mathbf{M}_1)^t \left[\frac{\Sigma_1 + \Sigma_2}{2} \right]^{-1} + \frac{1}{2} \ln \frac{\left| \frac{\Sigma_1 + \Sigma_2}{2} \right|}{\sqrt{\|\Sigma_1\| \|\Sigma_2\|}}$$

gde prva komponenta odgovara linearnoj separabilnosti, a druga seperabilnosti na osnovu različitosti kovariacionih matrica.

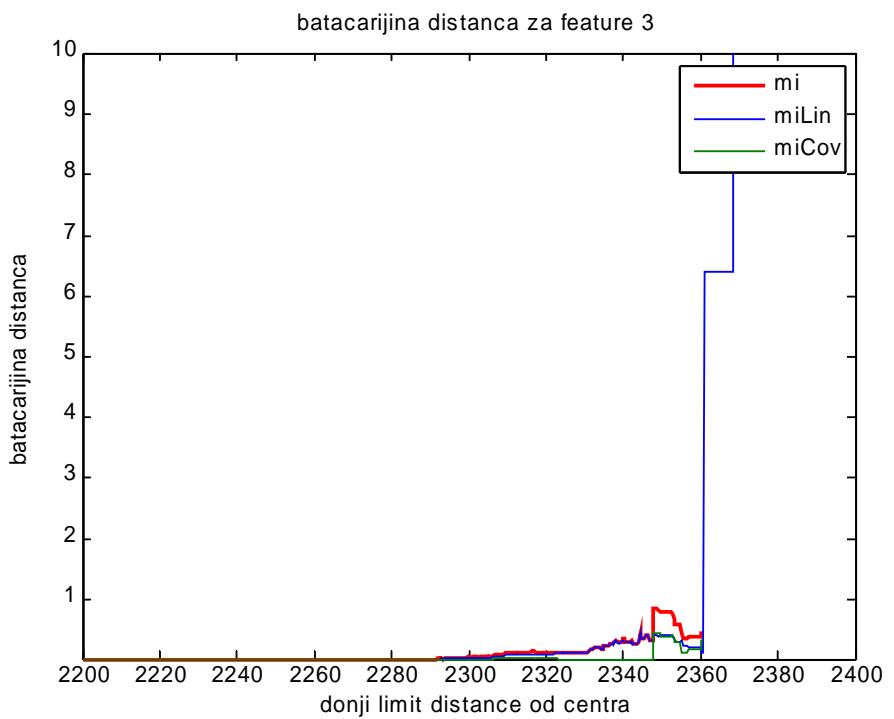
Na slikama je sa **mi** obeležena Batačarijina distanca, sa **miLin** komponenta koja potiče od linearne separabilnosti, a sa **miCov** komponenta koja potiče od razlike u kovariacionim matricama (u ovom slučaju varijansama). Neki od grafika se prekidaju u jednom trenutku. To su momenti kada te funkcije, zapravu, divergiraju u beskonačnost. Uzrok ovome su komponente **miCov** koje divergiraju u singularnim slučajevima (varijansa postaje jednaka ili bliska nuli).



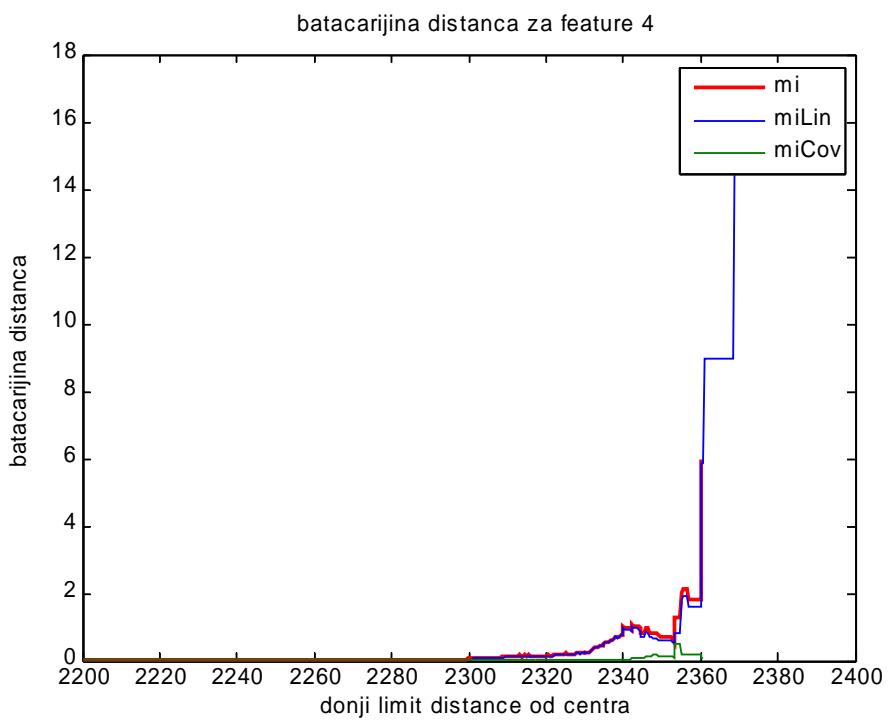
Sl.7.



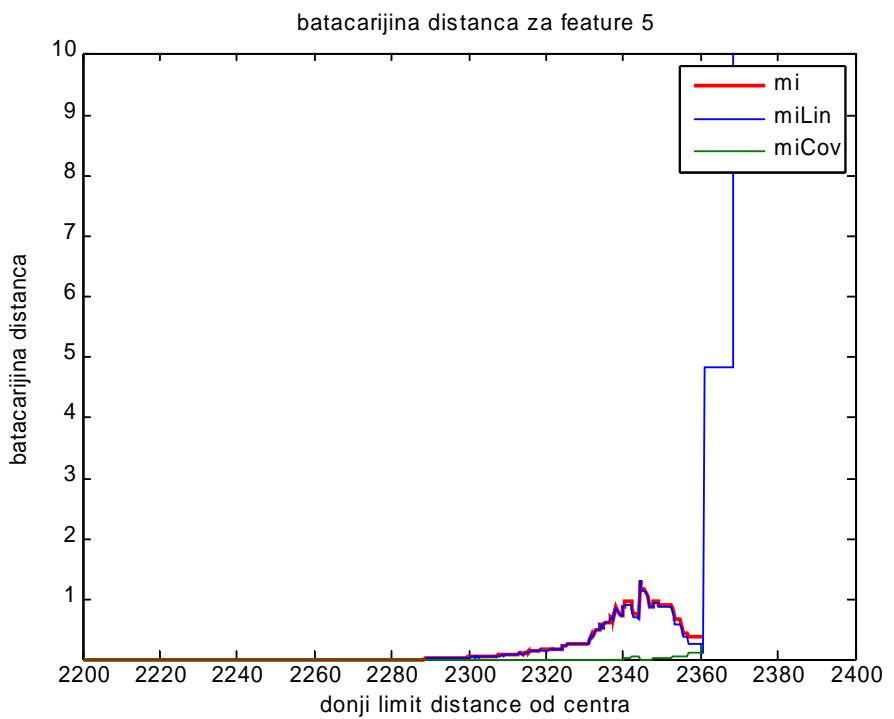
Sl.8.



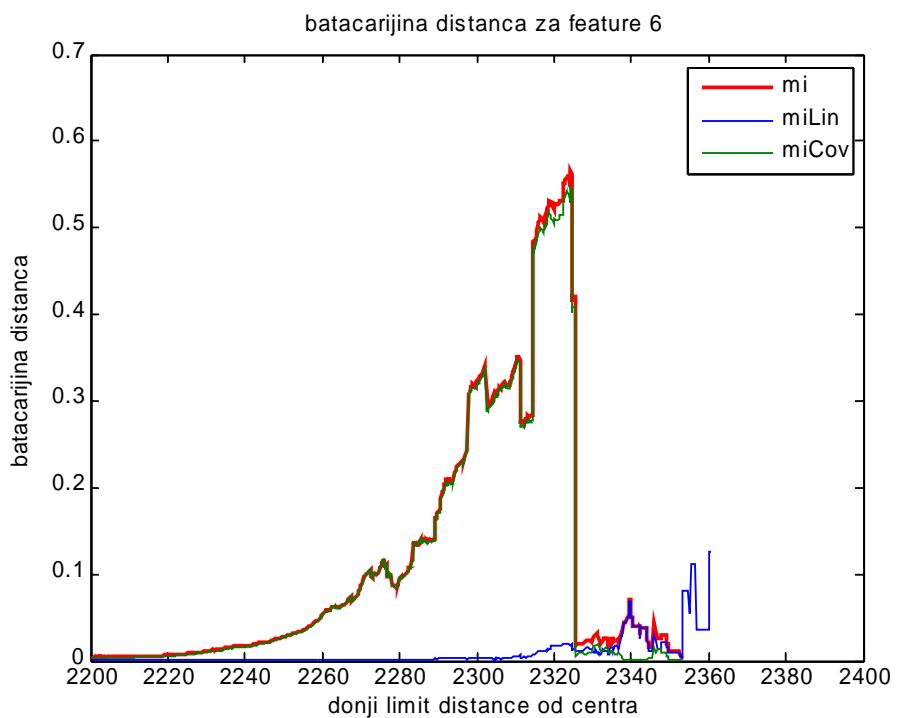
Sl.9.



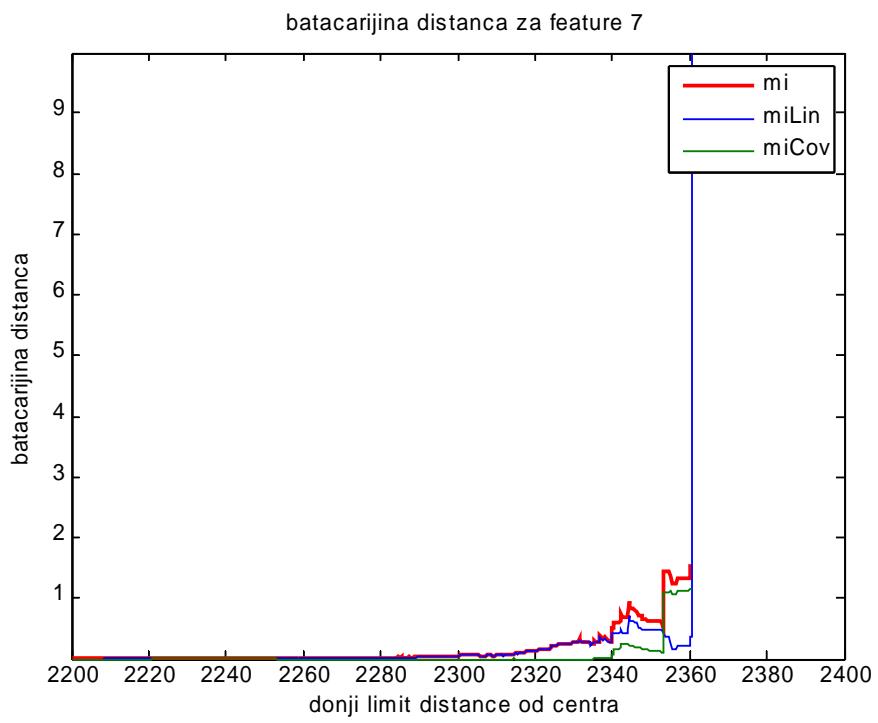
Sl.10.



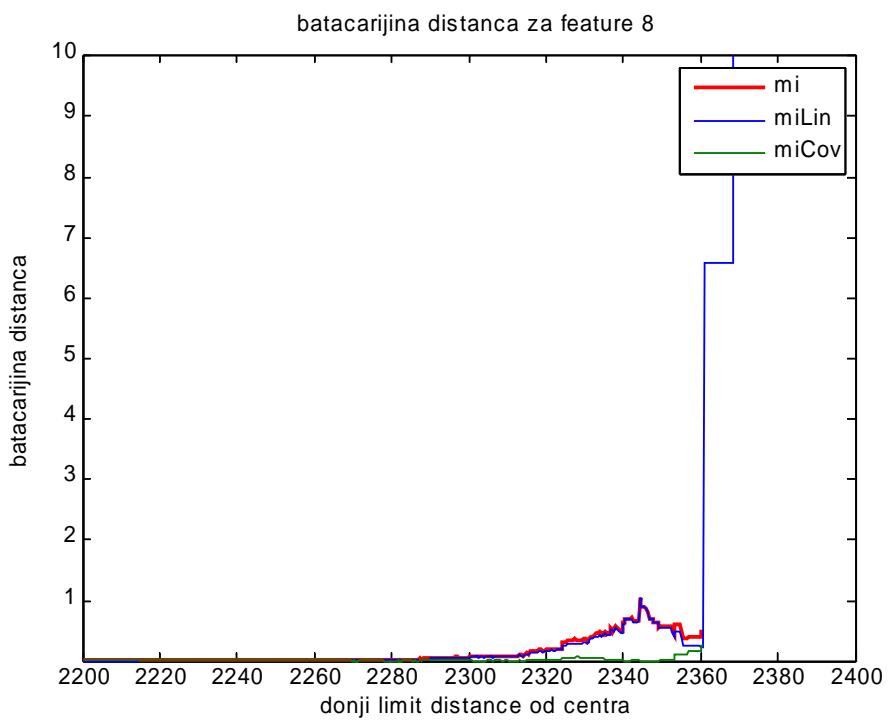
Sl.11.



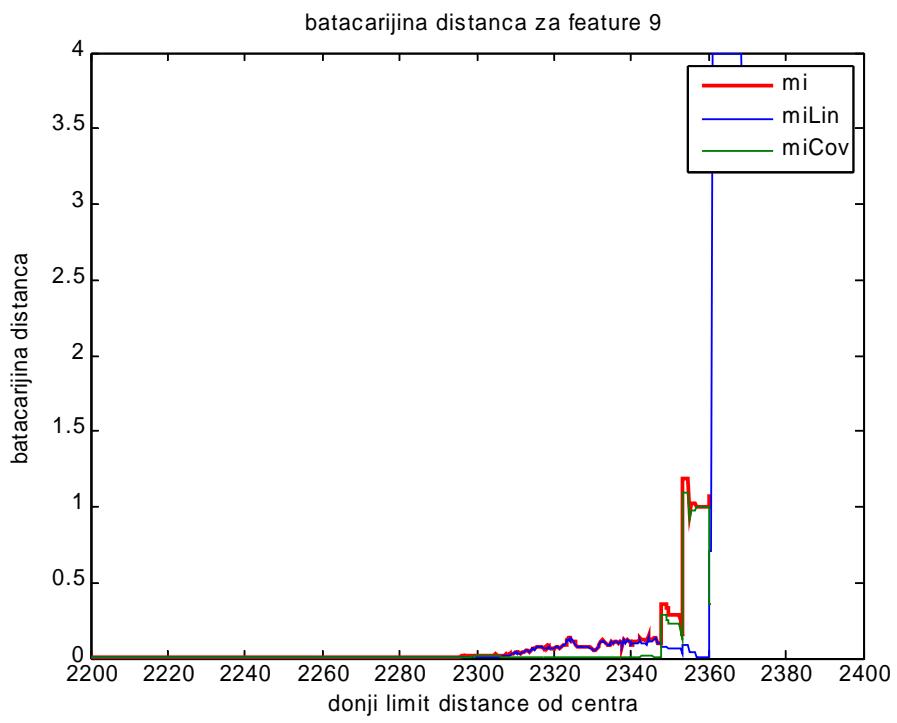
Sl.12.



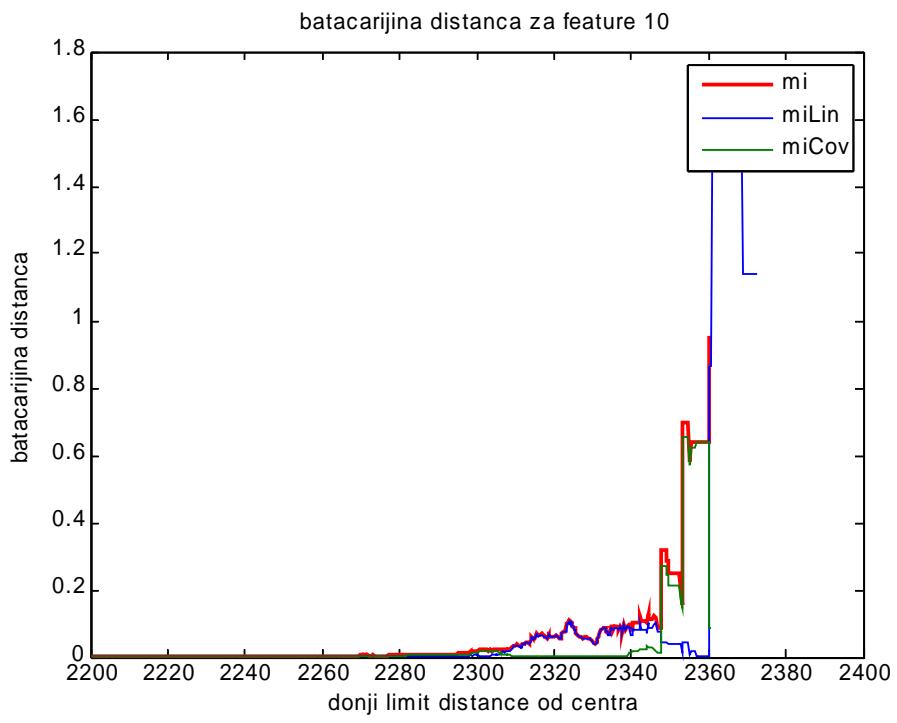
Sl.13.



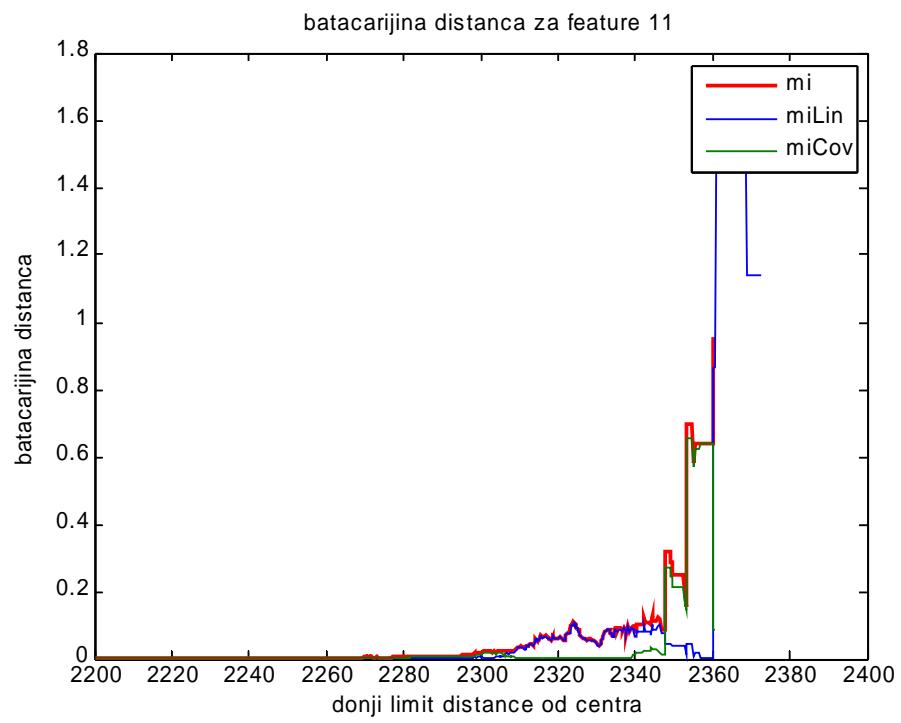
Sl.14.



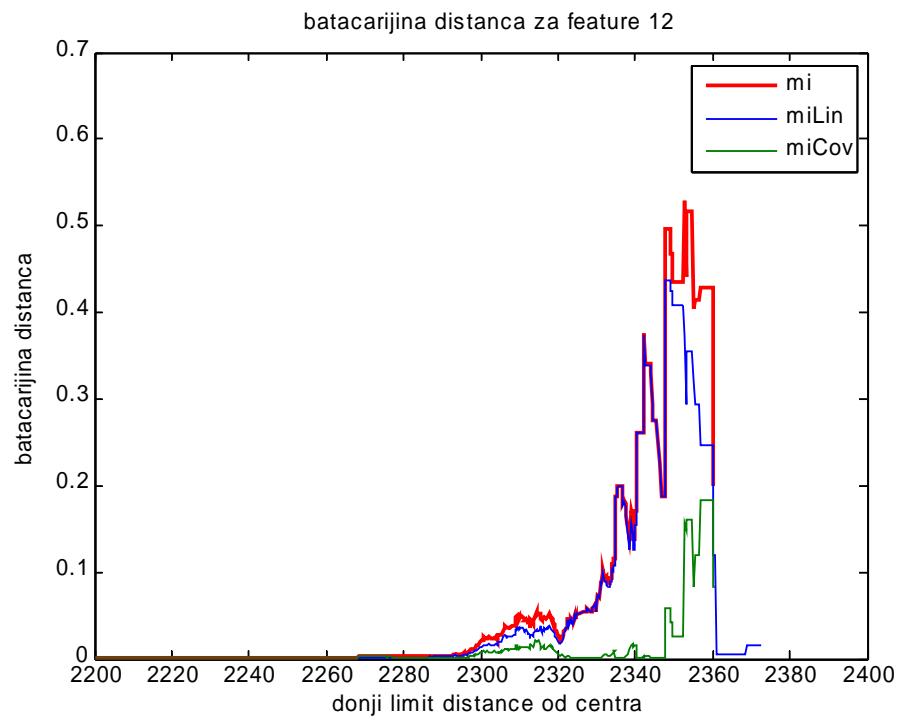
Sl.15.



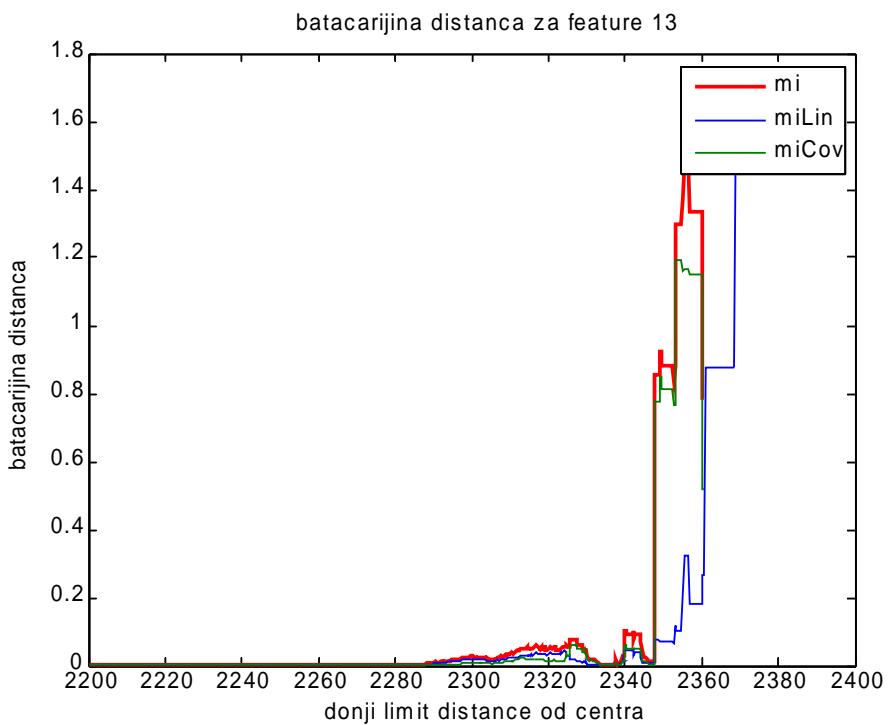
Sl.16.



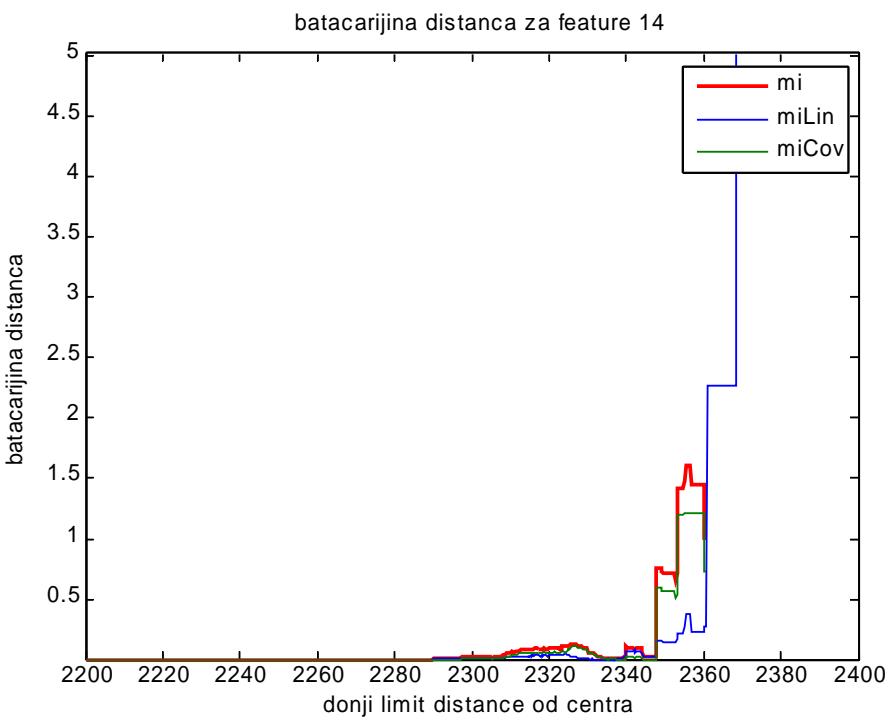
Sl.17.



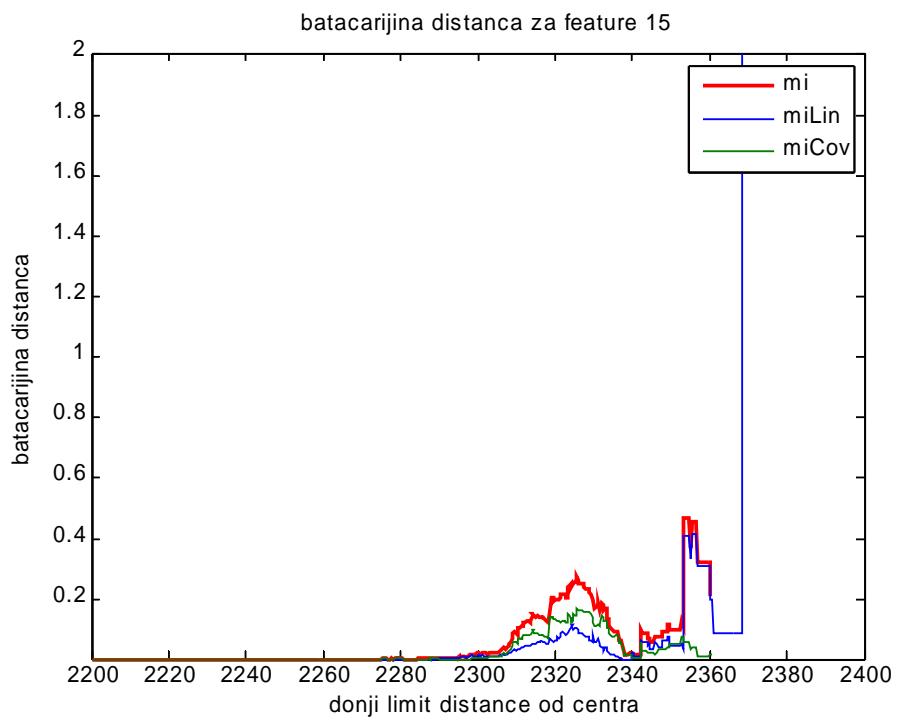
Sl.18.



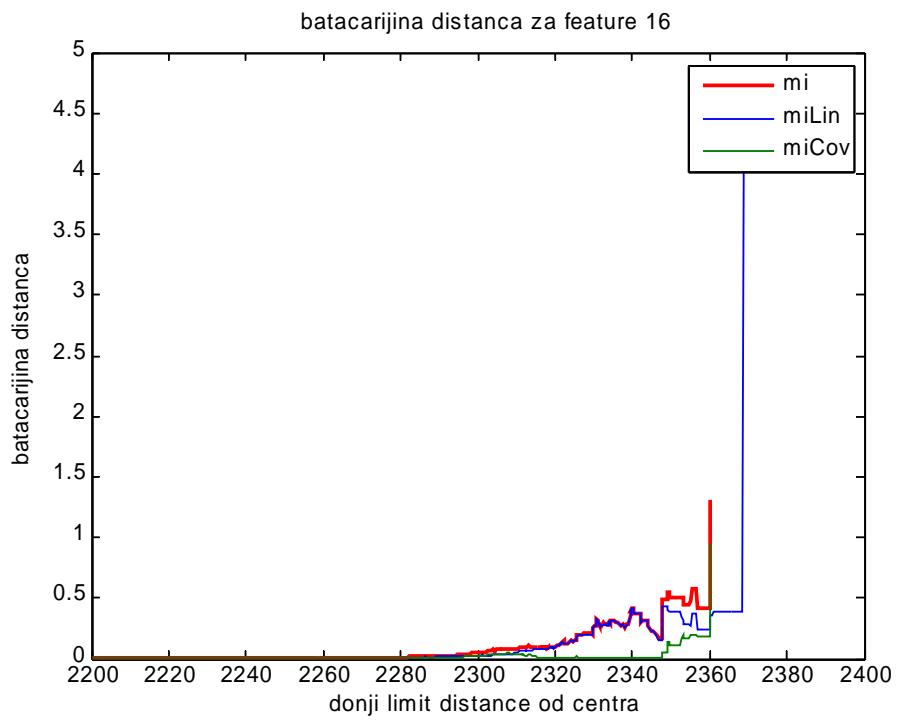
Sl.19.



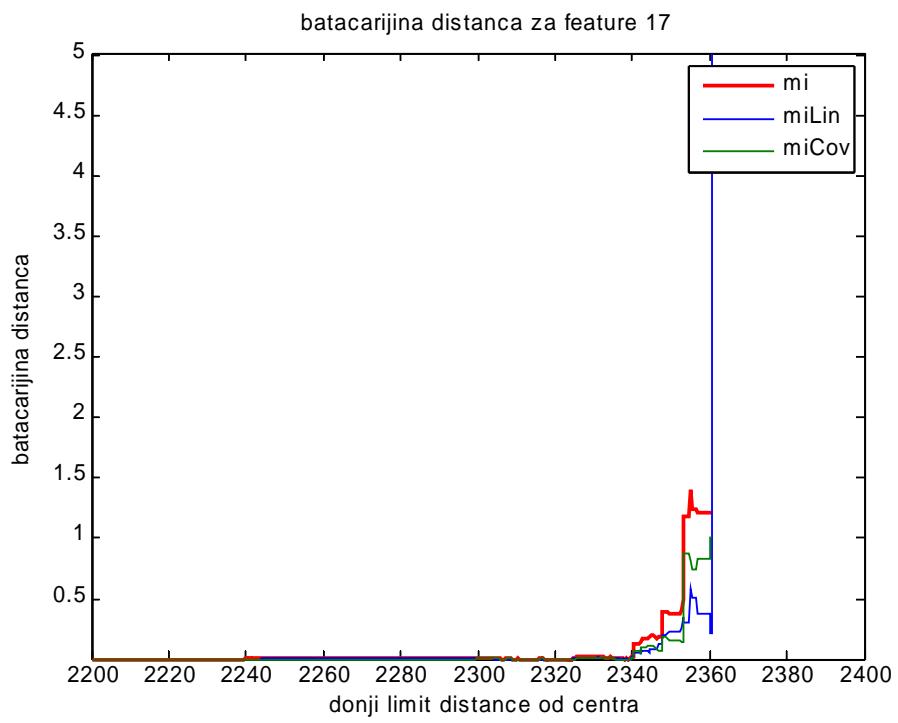
Sl.20.



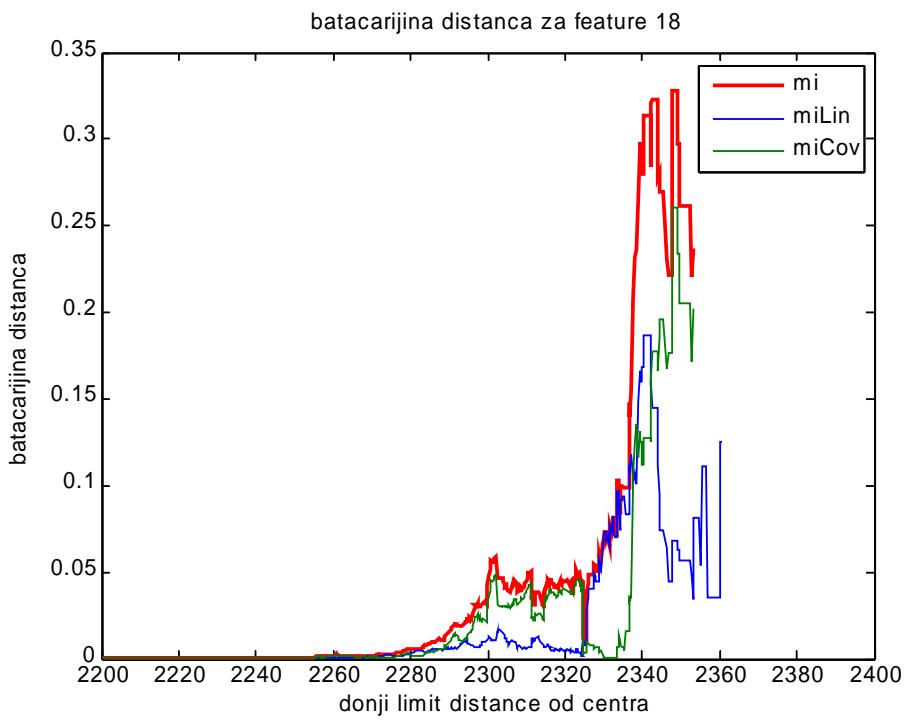
Sl.21.



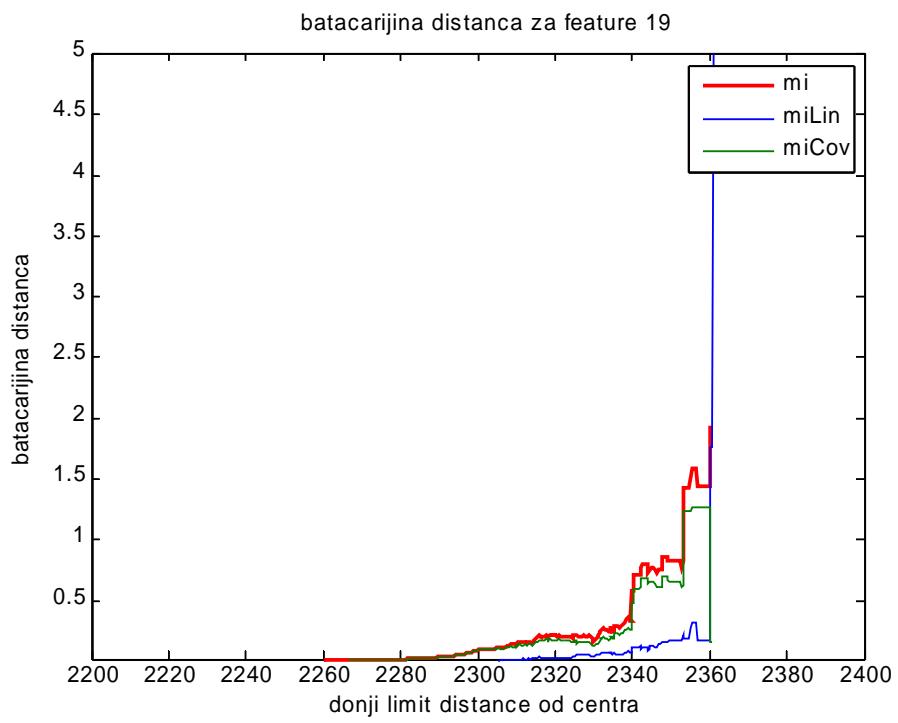
Sl.22.



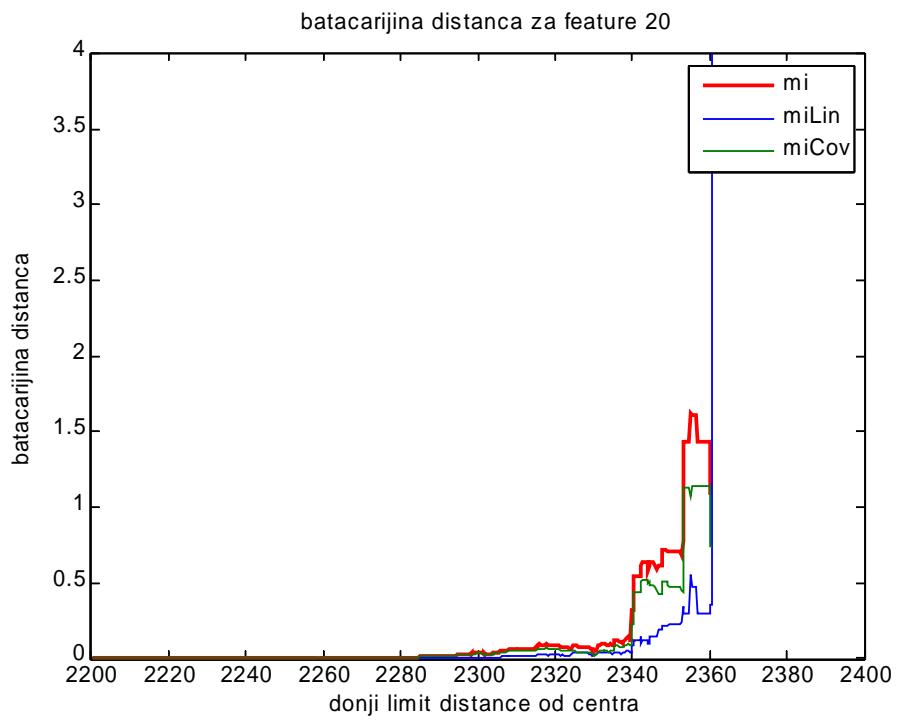
Sl.23.



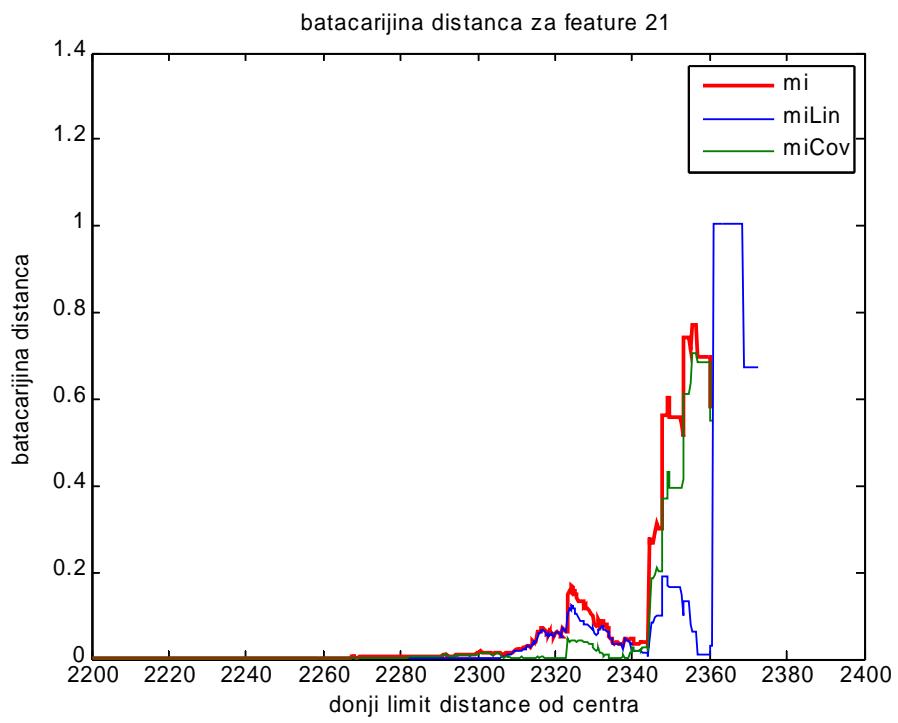
Sl.24.



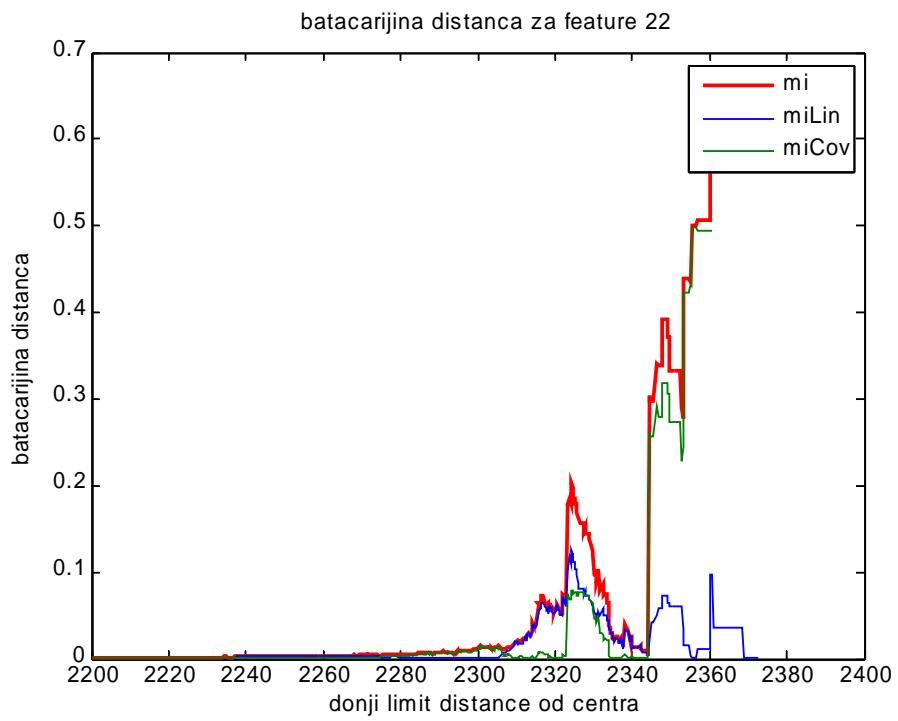
Sl.25.



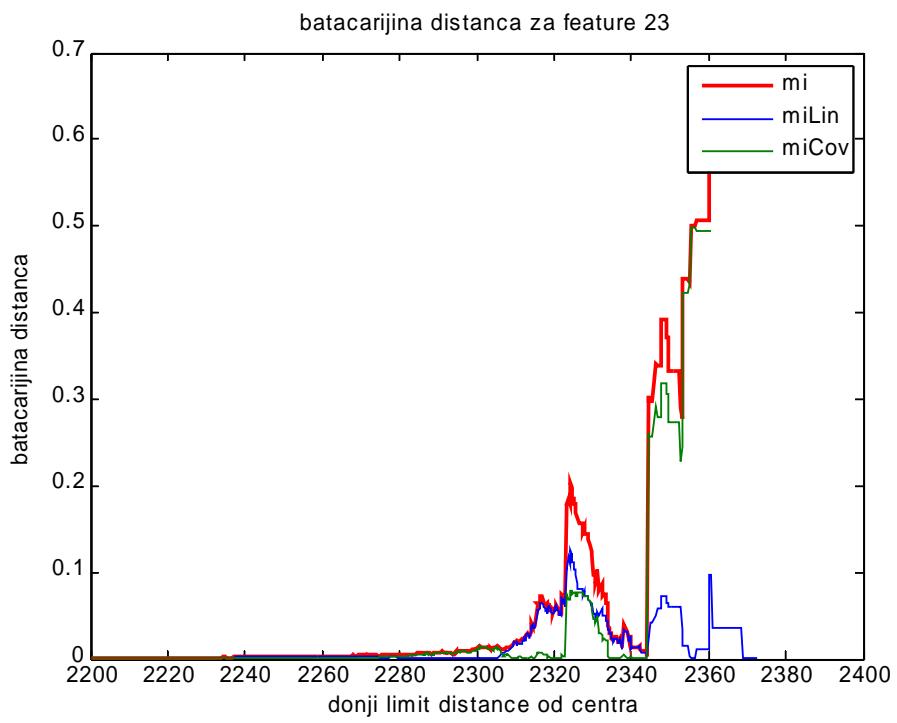
Sl.26.



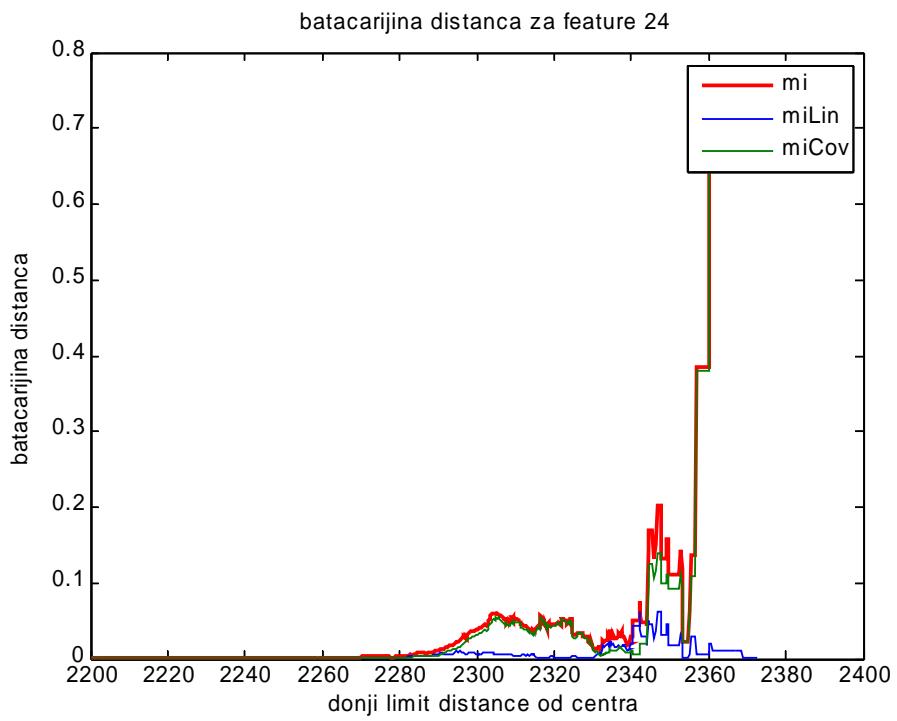
Sl.27.



Sl.28.



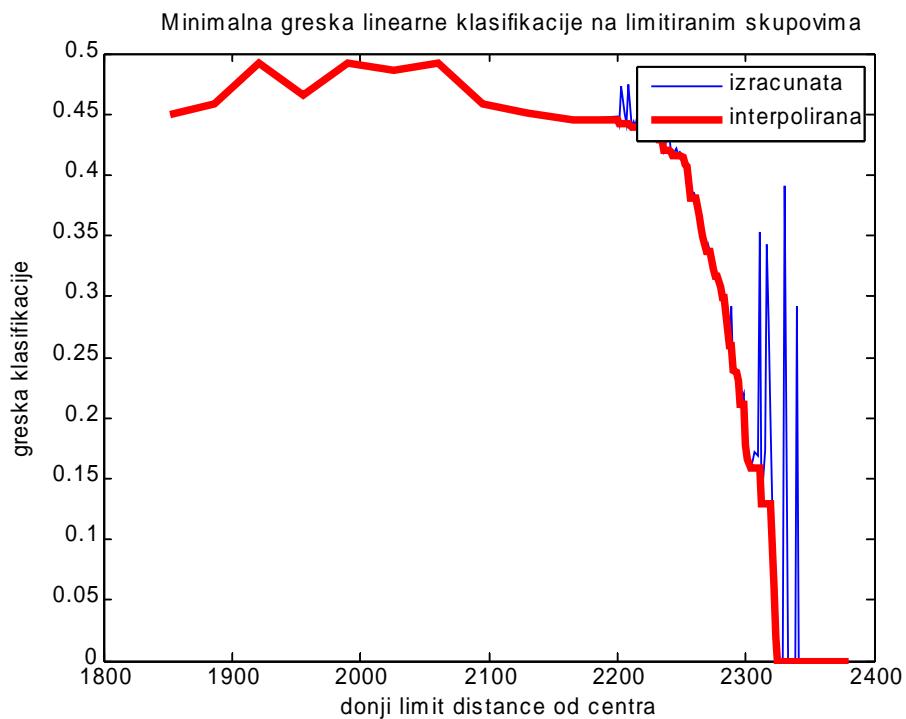
Sl.29.



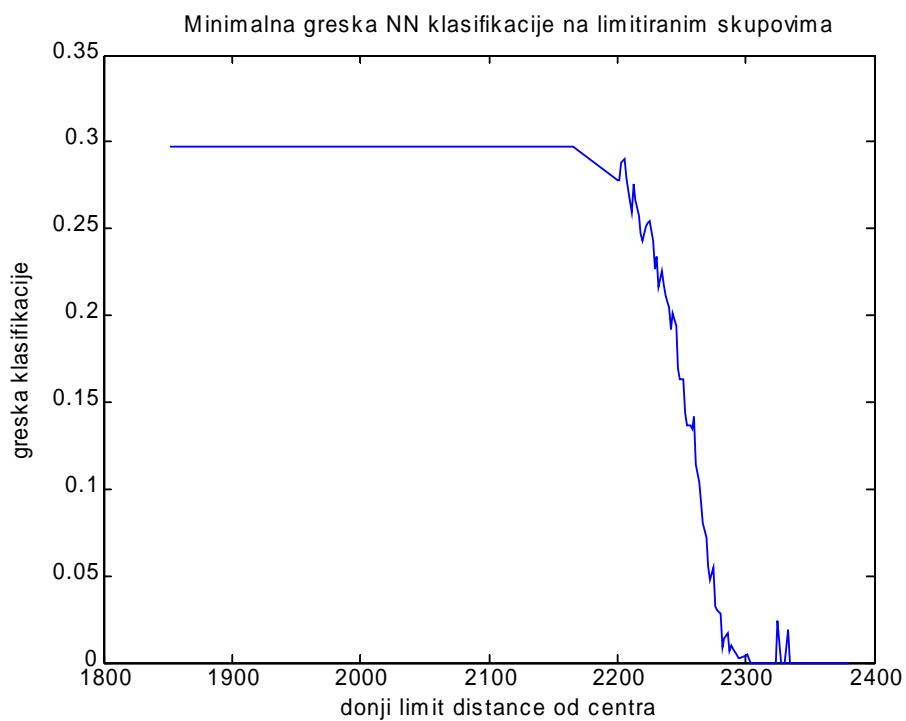
Sl.30.

Sa slika se jasno vidi da separabilnost među klasama raste sa redukcijom skupa podataka. Još bolji pokazatelj se nalazi na naredne dve slike. Za svaki od redukovanih skupova je računat linearni klasifikator i obučavana neuralna mreže. Za

projektovanje klasifikatora su korišćeni svi podaci i rezultujuće greške klasifikacije postavljaju donju granicu moguće greške na tom skupu.



Sl.31. Minimalna greška linearne klasifikacije na redukovanim skupovima



Sl.32. Minimalna greška NM klasifikacije na redukovanim skupovima

U slučaju linearnih klasifikatora su primetni skokovi posle distance od 2300. Na tim vrednostima kovariacione matrice teže singularnim matricima, što pravi probleme u proračunu klasifikatora. Klasifikatori su računati iterativno sa relativno malim brojem koraka, jer je ideja bila dobiti trend promene greške klasifikacije, a ne projektovanje najboljeg mogućeg klasifikatora. Crvenom linijom je prikazan trend promene greške klasifikacije kojom se izuzima uticaj preciznosti projekovanja.

Treba primetiti da se slična pojava javlja i na grafiku grešaka klasifikacije neuralnih mreža. Zbog drastično različitih opsega vrednosti pojedinih parametara, izvršeno je normiranje podataka pre samog procesa obučavanja mreže. S obzirom da u normiranju učestvuje kovariaciona matrica, ona je ponovo razlog pojave skokova greške klasifikacije.

4. Rešenje

1. Mreža linearnih klasifikatora

Linearni klasifikatori su oblika:

$$h(X) = V^t \cdot X + v_0 \begin{cases} < 0 \Rightarrow X \in \omega_1 \\ > 0 \Rightarrow X \in \omega_2 \end{cases}$$

gde je V vektor kolona dužine 24, X matrica dimenzija 24xn odbiraka za klasifikaciju, v0 skalar.

Parametri V i v0 su projektovani u iterativnom postupku. Prvo se računa V:

$$V = [s\Sigma_1 + (1-s)\Sigma_2]^{-1} \cdot (M_2 - M_1)$$

na osnovu čega se računa vrednost v00:

$$v_{00} = \frac{s\sigma_1^2 V^t M_2 + (1-s)\sigma_2^2 V^t M_1}{s\sigma_1^2 + (1-s)\sigma_2^2}$$

koja daje približnu vrednost parametra v0. Dalje se iterativno traži v0 u bliskoj okolini v00 kao vrednost koja daje najmanju grešku klasifikacije.

Posmatrajući sliku 6. i njoj odgovarajuću sliku 31. može se primetiti da čak i sa linearnim klasifikatorom možemo imati grešku klasifikacije blisku nuli, po cenu da klasifikator postane neodlučan u velikom broju situacija. U slučaju kada redukcija skupa ne izaziva potpuni gubitak informacija za pojedine sesije, klasifikator ima nepraktično veliku grešku klasifikacije. Otuda ideja da se napravi više linearnih klasifikatora, za različite redukovane skupove, čime bi se zadržala mogućnost donošenja odluka na svim sesijama, ali i povećala verovatnoća ispravne klasifikacije.

Za projektovanje klasifikatora korišćena je polovina skupa podataka koji je na raspolaganju. Druga polovina je podeljena na test podatke i validacione podatke. Kriterijum koji je trebalo minimizirati je $J = k \cdot trainErr + testErr$, sa parametrom k=0.5. Tu je prednost linearnog klasifikatora, jer iako podaci iz test skupa ne učestvuju direktno u projektovanju klasifikatora, ovakav pristup omogućava

konvergenciju greške i na test podacima. Izabrani kriterijum je, zapravo, ekvivalentan projektovanju više miliona linearnih klasifikatora od kojih ćemo zatim izabrati onaj koji daje najbolje rezultate na test podacima. Projektovano je ukupno 6 klasifikatora čije su karakteristike prikazane u tabeli 1.

#	trainErr	testErr
1	0.4337	0.4279
2	0.4038	0.3661
3	0.3596	0.3132
4	0.2450	0.2584
5	0.1154	0.1555
6	0	0.0339

Tabela 1. Performanse pojedinačnih linearnih klasifikatora

Sledeći korak je klasifikacija podataka. Rezultat svakog klasifikatora se vrednuje na osnovu apriorne verovatnoće greške datog klasifikatora. Za težinsku funkciju je odabrana $\exp(-4\text{err})$, gde je **err** apriorna verovatnoća greške klasifikacije. Na pozicijama na kojima više klasifikatora donosi odluku kao konačna vrednost se uzima odluka klasifikatora sa najmanjom verovatnoćom greške. Izlaz klasifikatora je, dakle, 0 za odbirke koji su izbačeni iz procesa odlučivanja, negativan za prvu klasu (pokret leve ruke) i pozitivan za drugu klasu (pokret pokret desne ruke). Klasifikator je stacionaran, tako da je izlaz klasifikatora za ulazni niz podataka, ekstrakovanih na gore opisan način, izlazni niz iste dužine čije vrednosti znatno variraju.

Na osnovu tog niza izlaznih podataka i usvojenog kriterijuma treba doneti konačnu odluku o pripadnosti cele sesije jednoj od klasa. Usvojena su tri kriterijuma za donošenje odluke:

- 1) Znak srednje vrednosti odziva mreže linearnih klasifikatora. Ako je odziv klasifikatora na ulazni niz vektora parametara $\mathbf{y}[\mathbf{k}]$, dužine \mathbf{n} , odluka se donosi na osnovu kriterijuma $f(\mathbf{y}[k]) = \text{sign}(\sum_{k=1}^n \mathbf{y}[k])$. Ako je vrednost kriterijumske funkcije jednaka 1, doneta je odluka da sesija pripada klasi 2, ako je vrednost kriterijumske funkcije \mathbf{f} jednaka -1, doneta je odluka da sesija pripada klasi 1.
- 2) Na osnovu odziva stacionarnog klasifikatora \mathbf{f} računa se funkcija $s[t] = \sum_{k=1}^t \mathbf{y}[k], 1 \leq t \leq n$, koja, efektivno, predstavlja odziv sekvenčnog klasifikatora. Kriterijumska funkcija je tada $f(s) = \text{sign}(\max_t(s[t])), 1 \leq t \leq n$.
- 3) Treća kriterijumska funkcija se takođe izvodi iz pomoćne funkcije $s[t]$, ali je ovaj kriterijum primenljiv i u realnom vremenu na neograničenom nizu odziva stacionarnog klasifikatora. Kriterijum je definisan sa

$$f(s) = s[t] \begin{cases} > a \Rightarrow \omega_2 \\ < b \Rightarrow \omega_1 \\ N/A, \text{else} \end{cases}$$

i svodi se na Wald-ov sekvenčnalni klasifikator.

Greške klasifikacije pojedinačnim kriterijumima primenjenim na izlaz mreže linearnih klasifikator su date u tabeli 2, dok je u tabeli 3 data performansa istih kriterijuma primenjenih na svaki od pojedinačnih linearnih klasifikatora čije su performanse date u tabeli 1.

kriterijum	greška klasifikacije [%]	kriterijum neodlučan [%]
1	41.04	0.00
2	39.62	0.00
3	44.71	1.89

Tabela 2. Performanse klasifikatora sa kriterijumskim funkcijama

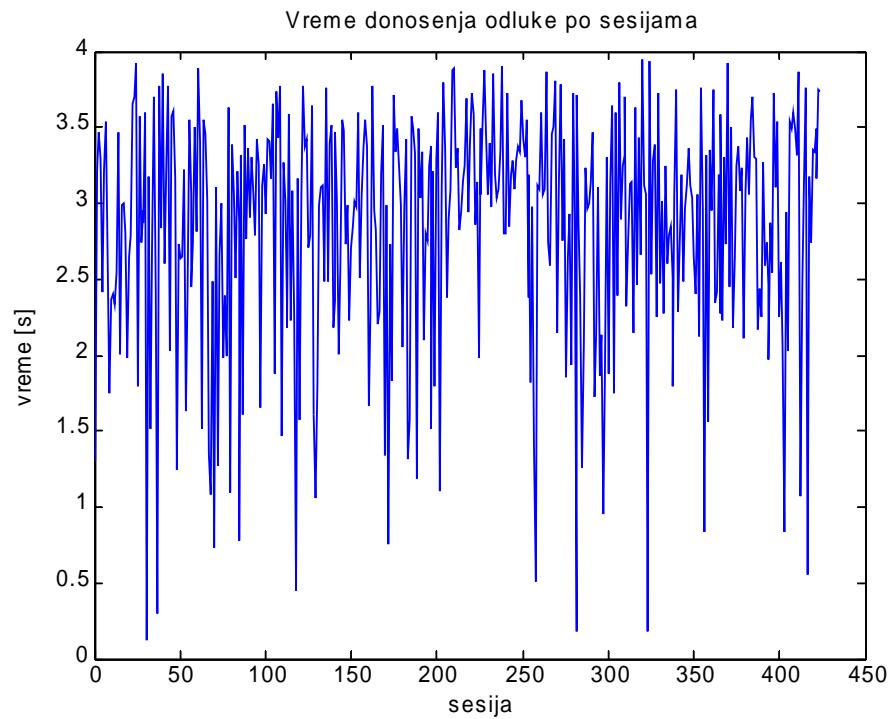
linearni klasifikator	kriterijum	greška klasifikacije [%]	kriterijum neodlučan [%]
1	1	42.22	0.00
	2	42.92	0.00
	3	44.10	2.12
2	1	47.04	12.26
	2	46.77	12.26
	3	40.57	50.00
3	1	42.96	31.37
	2	42.96	31.37
	3	38.67	57.31
4	1	38.15	59.20
	2	39.88	59.20
	3	36.84	73.11
5	1	28.79	84.43
	2	25.76	84.43
	3	28.13	84.91
6	1	4.76	95.05
	2	4.76	95.05
	3	4.76	95.05

Tabela 3. Performanse pojedinačnih klasifikatora sa kriterijumskim funkcijama

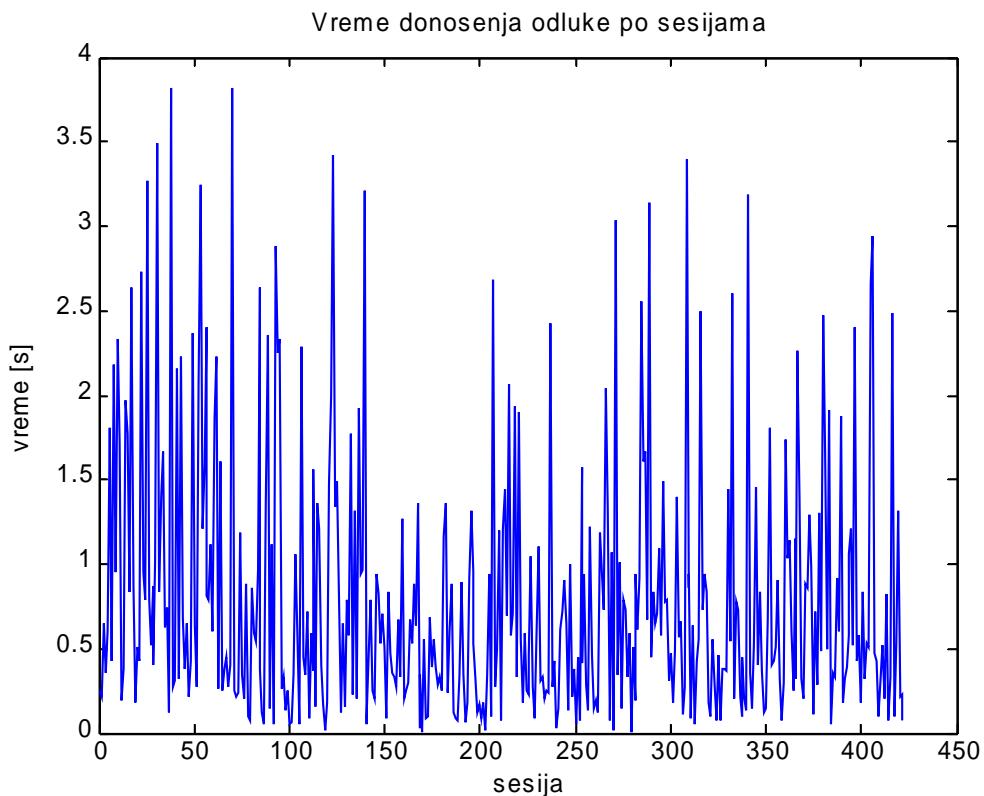
Treba istaći da su u slučaju treće kriterijumske funkcije granice odlučivanja u svim primenama bile postavljene na $a=0.3$ i $b=-0.3$. U tabeli 3 može da se primeti da je treći kriterijum za neke od linearnih klasifikatora imao znatno veći procenat neodlučnih sesija od ostala dva. U tim primerima je bilo moguće uzeti drugačije vrednosti za parametre **a** i **b** i, eventualno, dobiti bolje performanse. Ideja tabele 3 je da demonstrira doprinos svakog od klasifikatora u mreži konačnom rezultatu, pa otuda nije imalo smisla menjati vrednosti tih parametara.

Još jedan bitan podatak je i za koje se vreme donosi odluka. Očigledno je za prvu kriterijumsku funkciju neophodno sačekati kraj sesije da bi mogla da se upotrebni. Druga kriterijumska funkcija je takođe nekauzalna, ali možemo za vreme donošenja

odluke smatrati poziciju maksimalne udaljenosti. Za treći kriterijum se zaista i uzima vreme za koje je donešena odluka. Sva su vremena data u odnosu na triger.

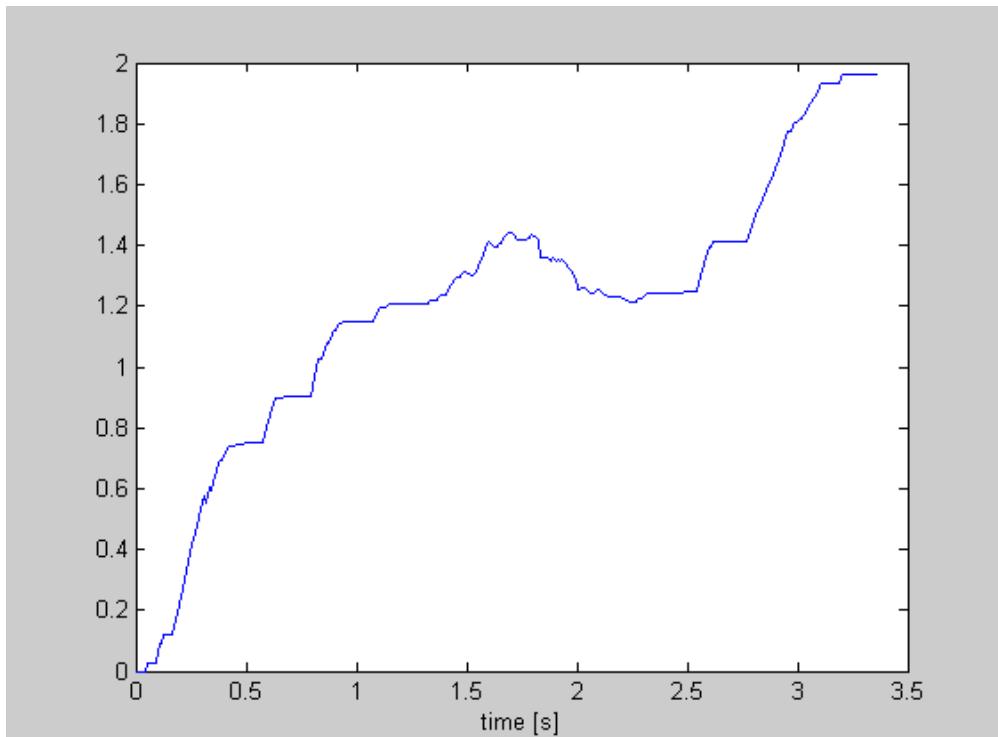


Slika 33. Vreme potrebno za donošenje odluke drugim kriterijumom. mean=2.84 sec, var=0.59

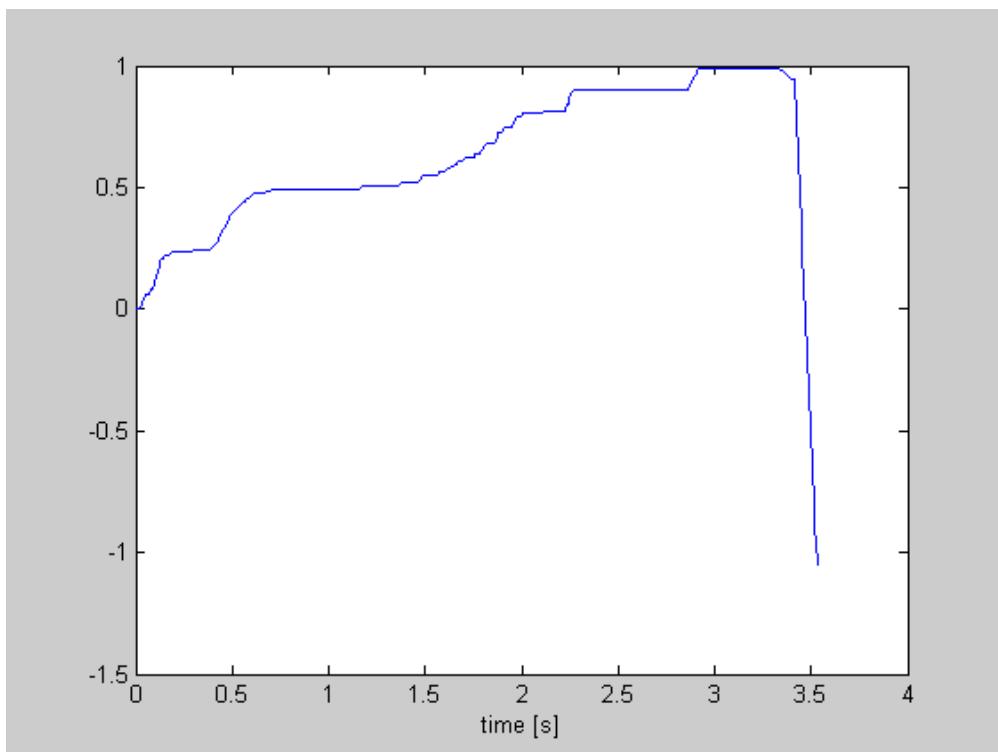


Slika 34. Vreme potrebno za donošenje odluke trećim kriterijumom. mean=0.79 sec, var=0.59

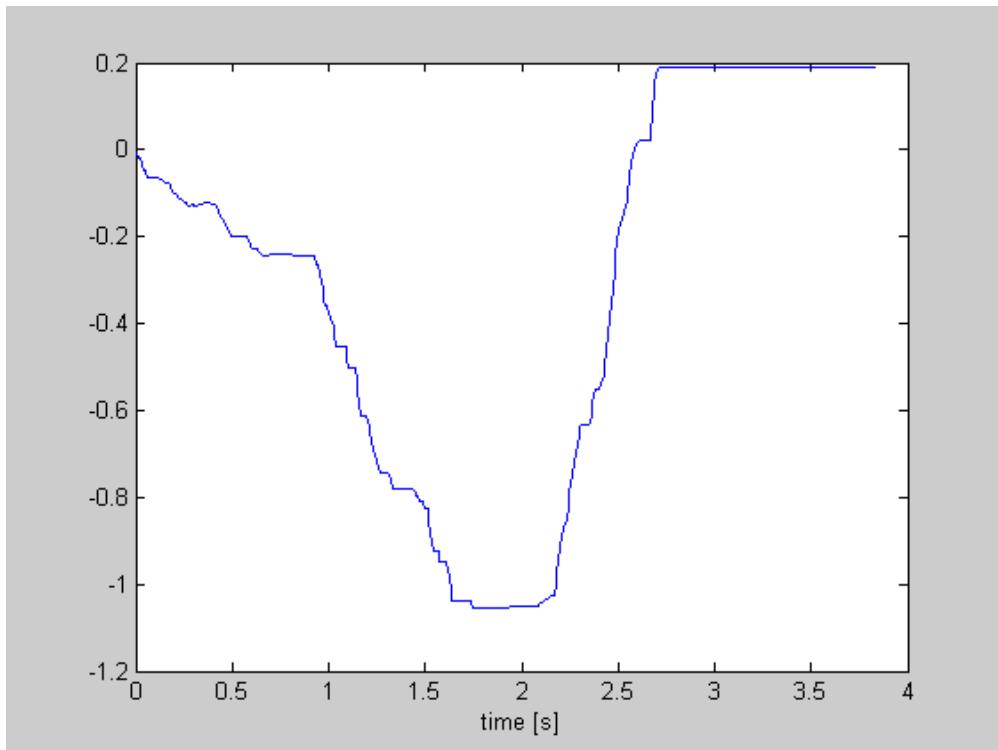
Na narednim slikama dati su primeri izgleda funkcije $s[t]$, za pojedine klase.



Slika 35. Odziv za drugu klasu gde i kriterijumi 2) i 3) donose ispravnu odluku



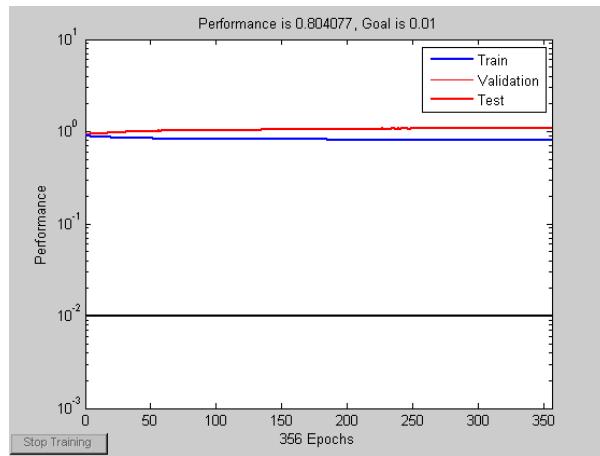
Slika 36. Odziv za prvu klasu gde kriterijum 2 donosi ispravnu odluku, ali kriterijum 3 ne



Slika 37. Odziv za prvu klasu gde i kriterijumi 2) i 3) donose ispravnu odluku

2. Klasifikatori sa neuralnim mrežama

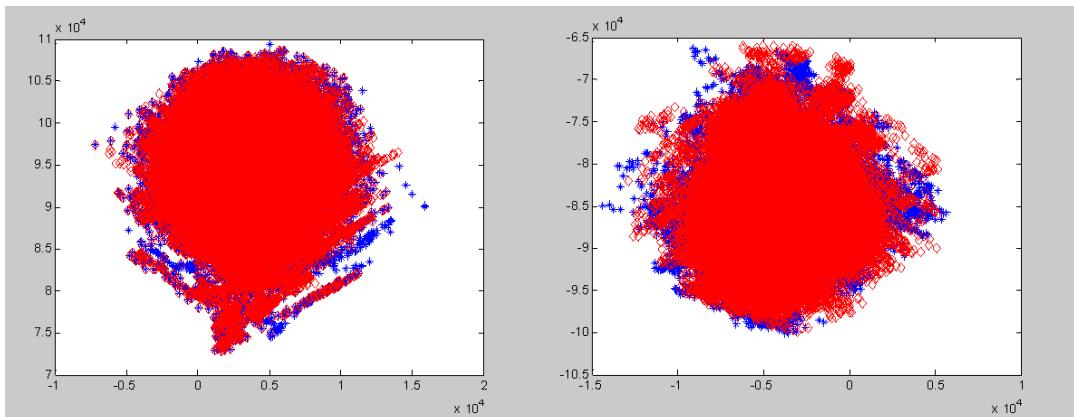
Iako se upoređivanjem slika 31 i 32 može zaključiti da je povoljnije rešenje praviti klasifikator sa neuralnim mrežama nego linearni klasifikator, to, ipak, nije slučaj. Pokazalo se da je veoma veliki problem da se ostvari konvergencija grešaka i na obučavajućem i na test skupu. Tipičan grafik performanse obučavanja je dat na slici 38, sa koje se vidi da smanjenje performanse na obučavajućem setu podataka ima sasvim suprotan efekat na test podatke. U originalnom radu [\[1\]](#), korišćen je evolutivni algoritam za određivanje metaparametara neuralne mreže. Pošto je tokom izrade ovog rada bilo tehnički nemoguće upotrebiti taj ili sličan pristup, neuralne mreže neće biti upotrebljene za klasifikaciju.



Slika 38. Performansa neuralne mreže u toku obučavanja

5. Diskusija

Izloženi klasifikatori su projektovani za subjekta 2 iz Gracove baze podataka navedenog eksperimenta. Pokazuje se da statistika raspodele parametara od subjekta do subjekta značajno varira, ali da bi procenom osnovnih parametara, srednje vrednosti i kovariacione matrice bilo moguće transformisati određenu raspodelu parametara u raspodelu nalik onoj na kojoj su projektovani klasifikatori. Veći problem je što se raspodela informacija po limitiranim skupovima drastično menja. Taj problem značajno ograničava primenljivost projektovanih klasifikatora.



Slika 39. Pogled na raspodelu parametara redukcijom dimenzija oblika za subjekta 1 (levo) i subjekta 2 (desno)

U tabeli 4 je data rang lista pobednika BCI Gratz takmičenja 2003.

mesto na rang listi	performansa klasifikatora greška klasifikacije [%]
1	10.71
2	15.71
3	17.14
4	13.57

Tabela 4. Performanse klasifikatora 4 pobednika Grac BCI takmičenja 2003.

U originalnom radu^[1], korišćena su tri tipa klasifikatora, linearni, klasifikatori sa neuralnim mrežama i SVM klasifikatori. Kriterijumska funkcija je MI (*Mutual Information*). U tabeli 5 je data performansa navedenih klasifikatora.

klasifikator	greška klasifikacije [%]
Neuralne mreže	10.00
SVM	10.00
Linearni	10.71

Tabela 5. Performanse klasifikatora projektovanih u originalnom radu^[1]

6. Literatura

- [1] Shang-Ming Zhou, John Q. Gan, Francisco Sepulveda, „Classifying mental tasks based on features of higher-order statistics from EEG signals in brain-computer interface“, *Information Sciences*, 2008.
- [2] Mingjun Zhong, Fabien Lotte, Mark Girolami, Anatole Lecuyer, „Classifying EEG sfor brain computer interfaces using Gaussian processes“, *Information Sciences*, 2007.
- [3] F. Cincotti, D. Mattia, F. Aloise, S. Bufalari, L. Astolfi, F. De Vico Fallani , A. Tocci ,L. Bianchi, M.G. Maraciani, Shangkai Gao, J. Millan, F. Babiloni, „High-resolution EEG techniques for brain-computer interface applications“, *Information Sciences*, 2007.
- [4] A. Ferreira, W. C. Celeste, F. A. Cheein, T. F. Bastos-Filho, M. Sarcinelli-Filho, R. Carelli, „Human-machine interfaces based on EMG and EEG applied to robotics systems“, *Journal od NeuroEngineering and Rehabilitation*, 2008.
- [5] F. Sepulveda, „Artificial neural network techniques in human mobility rehabilitation“, *book chapter for „Computer Techniques in Medical and Biotechnology systems“*, 1999.
- [6] Ž. Đurović, „Prepoznavanje oblika“, 2008.
- [7] A. Papoulis, S. Unikricschna Pillai, “Probability, random variables, and stochastic processes”, *McGrawHill*, 2002.

Sadržaj

1. Uvod.....	1
2. Eksperiment.....	2
2.1. Opis eksperimenta.....	2
3. Analiza podataka.....	3
3.1. Ekstrakcija parametara za klasifikaciju.....	3
3.2. Analiza parametara.....	5
4. Rešenje.....	20
4.1. Mreža linearnih klasifikatora.....	20
4.2. Klasifikatori sa neuralnim mrežama.....	25
5. Diskusija.....	26
6. Literatura.....	27