Univerzitet u Sarajevu Elektrotehnički fakultet Odsjek za automatiku i elektroniku

# KORIŠTENJE ENF SIGNALA ZA VREMENSKU I PROSTORNU LOKALIZACIJU MULTIMEDIJALNIH SIGNALA

Završni rad II ciklusa studija

Mentor:

Red.prof.dr Melita Ahić-Đokić, dipl. el. ing.

Kandidat:

Jasmina Zubača, BoEE

Sarajevo, septembar 2016

Univerzitet u Sarajevu Elektrotehnički fakultet Odsjek za automatiku i elektroniku Završni rad II ciklusa studija

# Izjava o autentičnosti rada

Ime i prezime: Jasmina Zubača

Naslov rada: Korištenje ENF signala za vremensku i prostornu lokalizaciju multimedijalnih signala

Vrsta rada: Završni rad II ciklusa studija

Broj stranica: 72

#### Potvrđujem:

- da sam pročitala dokumente koji se odnose na plagijarizam, kako je to definirano Statutom Univerziteta u Sarajevu, Etičkim kodeksom Univerziteta u Sarajevu i pravilima studiranja koja se odnose na I i II ciklus studija, integrirani studijski program I i II ciklusa i III ciklus studija na Univerzitetu u Sarajevu, kao i uputama o plagijarizmu navedenim na web stranici Univerziteta u Sarajevu;
- da sam svjesna univerzitetskih disciplinskih pravila koja se tiču plagijarizma;
- da je rad koji predajem potpuno moj, samostalni rad, osim u dijelovima gdje je to naznačeno;
- da rad nije predat, u cjelini ili djelimično, za stjecanje zvanja na Univerzitetu u Sarajevu ili nekoj drugoj visokoškolskoj ustanovi;
- da sam jasno naznačila prisustvo citiranog ili parafraziranog materijala i da sam se referirala na sve izvore;
- da sam dosljedno navela korištene i citirane izvore ili bibliografiju po nekom od preporučenih stilova citiranja, sa navođenjem potpune reference koja obuhvata potpuni bibliografski opis korištenog i citiranog izvora;
- da sam odgovarajuće naznačila svaku pomoć koju sam dobila pored pomoći mentorice i akademskih tutora.

Mjesto, datum \_\_\_\_\_

Potpis \_\_\_\_\_

Red. prof. dr Melita Ahić-Đokić, dipl. el. inž. Viši ass. dr Emir Sokić Odsjek za automatiku i elektroniku Sarajevo, 22.12.2015.

# Tema za završni rad

studenta II ciklusa studija koji studira na ETF-u u skladu sa principima Bolonjskog procesa na Odsjeku za automatiku i elektroniku (st.g. 2015/16)

# Tema: Korištenje ENF signala za vremensku i prostornu lokalizaciju multimedijalnih signala

### Student: Zubača Jasmina

#### Sažetak:

Tema rada je vezana za vremenski promjenljiv lokacijski-zavisan potpis električne mreže, koji postaje obuhvaćen u snimanju multimedijalnih signala zbog direktnih ili indirektnih uticaja pripadne električne mreže. Tema obuhvata obradu signala i informacijsku sigurnost/forenziku. ENF signal predstavlja promjenljivu vrijednost trenutne frekvencije električne mreže tokom vremena.

U okviru rada potrebno je korištenjem ENF signala odrediti vrijeme i lokaciju nastanka multimedijalnih snimaka. U okviru rada zadatak studenta je da obradi:

- ekstrakciju ENF signala iz multimedijalnih signala,
- obradi ENF signal uz određivanje statističkih značajki,
- izgradi sistem mašinskog učenja koji omogućava klasifikaciju ENF signala u smislu njihovog porijekla uz prethodno učenje karakteristika ENF signala različitih mreža.

#### Polazna literatura:

- 1. Melita Ahić-Đokić, "Signali i sistemi", Elektrotehnički fakultet u Sarajevu, 2010
- 2. Alan J. Cooper, "An automated approach to the ENF criterion", Equinox Publishing, 2009
- 3. Tarek El Gemayel, "Feasibility of using ENF fluctuations to perform forensic digital audio authentication", School of Electrical Engineering and Computer Science Canada, 2013
- 4. Ravi Garg, Adi Hajj-Ahmad, Min Wu, "*Geo-location estimation from ENF signals*", University of Maryland, 2013
- 5. Adi Hajj-Ahmad, Ravi Garg, Min Wu, "Instantaneous frequency estimation and localization for ENF signals", University of Maryland, 2012

- 6. Sumit Kumar, "Complexity and precision analysis of DFT based ENF extraction methods", IJCST, 2014
- 7. Wei-Hong Chuang, Ravi Garg, Min Wu, *"How secure are power network signature based time stamps"*, ACM conference, 2012
- 8. Catalin Grigoras, "*Digital audio recording analysis The ENF criterion*", Diamond Cut Productions, 2003
- 9. Ravi Garg, "Time and location forensics for multimedia", University of Maryland, 2003
- 10. Ode Ojowu, "*ENF extraction from digital recordings using adaptive techniques and frequency tracking*", IEEE transaction on information forensics and security, 2012

Red. prof. dr Melita Ahić-Đokić

#### Zahvala:

Veliku zahvalnost, prije svega, dugujem svojim mentorima red. prof. dr Meliti Ahić-Đokić i doc. dr Emiru Sokiću koji su mi pomagali svojim savjetima pri izradi ovog završnog rada, i što su uvijek imali strpljenja i vremena za moja brojna pitanja.

Također, zahvaljujem se svim svojim prijateljima i prijateljicama koji su uvijek bili uz mene, i bez kojih cijeli ovaj tok mog studiranja ne bi prošao tako lako i zabavno.

Posebnu zahvalnost iskazujem cijeloj svojoj porodici koja me je uvijek podržavala i upućivala na pravi put.

I na kraju, najveću zaslugu za ono što sam postigla pripisujem svojim roditeljima koji su uvijek bili tu, uz mene, bez obzira da li se radilo o teškim ili sretnim trenucima, i bez kojih sve ovo što sam do sada postigla ne bi bilo moguće.

Veliko HVALA svima!

## Sažetak

U okviru rada prezentovan je postupak gradnje sistema mašinskog učenja s ciljem klasifikacije ENF signala u smislu njihovog porijekla. ENF signal predstavlja vremenski promjenljivu vrijednost trenutne frekvencije električne mreže.

U prvom dijelu rada dat je kratak uvod u analizu i ekstrakciju ENF signala iz multimedijalnih snimaka. Također, opisane su parametarske i neparametarske metode za ekstrakciju ENF signala, od kojih se posebno izdvajaju metode bazirane na spektrogramu.

Glavni dio rada obuhvata ekstrakciju ENF signala iz audio i mrežnih snimaka, te određivanje statističkih značajki koje kvantitativno opisuju ENF signale. Pored toga, detaljno su opisane mašine vektorske podrške koje čine model za klasifikaciju ENF signala. Na kraju su objašnjene i prikazane faze treniranja i testiranja klasifikatora. Također, prikazani su rezultati klasifikacije snimaka i data su odgovarajuća objašnjenja.

## Abstract

This paper presents the procedure of constructing a machine learning system with the purpose of the classification of ENF signals in terms of their origin. ENF signal represents the changing value of the current frequency of the electrical network in time.

The first part of the work gives a brief introduction to the analysis and extraction of ENF signals from multimedia recordings. Moreover, it describes the parametric and nonparametric methods for the extraction of ENF signals, with particular emphasis on methods based on the spectrogram.

The main part of the work involves the extraction of ENF signals from audio and network recordings, as well as the determination of the statistical characteristics which quantitatively describe the ENF signals. Furthermore, support vector machines, which make the model for the classification of ENF signals, are described in detail. At the end of the work, phases of training and testing classifiers are explained and presented. In addition, the results of the classification of recordings are appropriately explained.

# Sadržaj

Sažetak	
Abstract	
1. Uvod	1
2. Frekvencija elektroenergetske mreže	4
2.1. Analiza ENF signala	6
3. Ekstrakcija ENF signala	7
3.1. Neparametarske metode	
3.1.1. Metoda spektrograma	
3.1.2. Vremenski rekurzivni iterativni adaptivni algoritam	12
3.2. Parametarske metode	13
4. Ekstrakcija ENF signala iz signala poznate frekvencije	15
4.1. Testni signal bez šuma	16
4.2. Testni signal sa šumom	
5. Opis baze multimedijalnih zapisa	
5.1. Ekstrakcija ENF signala iz audio snimaka i snimaka mreže	
6. Analiza i ekstrakcija značajki ENF signala	
6.1. Vremenski domen ENF signala	
6.2. Wavelet analiza ENF signala	
6.3. Autoregresivni (AR) model ENF signala	
6.4. Autoregresivni model sa pokretnom srednjom vrijednošću (ARMA)	
6.5. Dodatni parametri za opis ENF signala	
6.6. Normalizacija statističkih značajki	
6.7. Prikaz statističkih značajki	
6.8. Odabir statističkih značajki	
7. Sistem mašinskog učenja	
7.1. Klasifikacija podataka	40
7.2. Mašine vektorske podrške	

8. Klasifikacija signala	45
8.1. Faza treniranja klasifikatora	46
8.2. Faza testiranja klasifikatora	49
9. Zaključak	53
Literatura	54
Lista slika	56
Lista tabela	57
Prilog A	58
Prilog B	59
Prilog C	60
Prilog D	61
Prilog E	62
Prilog F	63
Prilog G	64

# 1. Uvod

Posljednjih nekoliko godina, veliki broj digitalnih informacija je dostupan u obliku audio snimaka, video snimaka, slika i mnogo drugih oblika zapisa. Navedeni zapisi mogu sadržavati metapodatke (eng. *metadata*), koji daju vrlo bitne informacije o vremenu i lokaciji nastanka snimka [1].

Međutim, moguće je izvršiti modifikaciju pohranjenih podataka koristeći razne digitalne alate. Neki od primjera izmjene audio snimaka su:

- uklanjanje isječka iz originalnog snimka,
- umetanje stranog isječka u originalni snimak,
- izmjena vremena i datuma snimanja u polju metapodataka.

Prethodno navedene izmjene je moguće postići i kod video snimaka, kao i kod drugih oblika zapisa. Na slici 1.1 je prikazana modifikacija originalnog snimka uklanjanjem isječka iz originalnog snimka.



Slika 1.1. Uklanjanje isječka iz originalnog snimka [2]

Ukoliko se multimedijalni snimci koriste kao dokazni materijal u pravnim ili novinarskim slučajevima, pomenute modifikacije mogu dovesti do ozbiljnih posljedica. Iz tog razloga je neophodno izvršiti provjeru autentičnosti digitalnih snimaka koristeći razne metode autentifikacije, koje se razvijaju i koriste u multimedijalnoj forenzici (eng. *multimedia forensics*) [1]. Jedna od metoda za provjeru autentičnosti zapisa se bazira na frekvenciji

1

elektroenergetske mreže (eng. *Electrical Network Frequency-ENF*). ENF signal predstavlja promjenljivu vrijednost trenutne frekvencije elektroenergetske mreže u vremenu.

Autentifikacija zapisa predstavlja proces utvrđivanja originalnosti multimedijalnog (audio ili video) zapisa. Proces autentifikacije audio zapisa je moguće podijeliti na dva glavna dijela. Prvi dio se bazira na snimanju ENF signala direktno iz električne mreže, kako bi se izgradila referentna baza podataka. Drugi dio se bazira na ekstrakciji ENF signala prilikom snimanja audio zapisa. Slika 1.2. prikazuje korake koji su potrebni za autentifikaciju audio zapisa.



*Slika 1.2. Koraci autentifikacije audio zapisa* [1]

Pored toga što je ENF signal koristan za autentifikaciju zapisa, njegova upotreba i značaj su mnogo širi. Neke od mogućih primjena su:

- određivanje lokacije nastanka multimedijalnog zapisa,
- određivanje vremena nastanka multimedijalnog zapisa,
- detekcija mogućih modifikacija multimedijalnog zapisa.

Predmet ovog završnog rada je dizajniranje sistema mašinskog učenja s ciljem klasifikacije ENF signala u smislu njihovog porijekla. Za realizaciju završnog rada će se koristiti baza multimedijalnih zapisa, koja će biti detaljno objašnjena. Bitno je napomenuti da se pretpostavlja autentičnost dostupnih multimedijalnih zapisa.

U prvom i drugom poglavlju rada dat je kratak uvod u frekvencije elektroenergetskih mreža, i objašnjeni su razlozi zbog kojih multimedijalni zapisi sadrže ENF signale. Također, prikazana je analiza ENF signala i istaknute su posljedice u slučaju netačne estimacije ENF signala.

Treće poglavlje opisuje ekstrakciju ENF signala iz multimedijalnih zapisa. Navedene su parametarske i neparametarske metode za ekstrakciju ENF signala, od kojih su posebno izdvojene metode bazirane na spektrogramu.

Četvrto poglavlje prikazuje implementaciju metoda baziranih na spektrogramu. Kako bi se utvrdila tačnost pojedinačnih metoda, izvršena je ekstrakcija ENF signala iz signala poznate frekvencije korištenjem istih. Konačna metoda ekstrakcije, korištena u daljnjoj implementaciji završnog rada, je odabrana poređenjem dobivenih rezultata.

U petom poglavlju su detaljno opisane karakteristike baze multimedijalnih zapisa iz različitih elektroenergetskih mreža, a koji su korišteni za gradnju klasifikatora. Također, objašnjen je princip rada algoritma za ekstrakciju ENF signala iz audio snimaka i snimaka mreže. Na kraju su prikazani ekstrahovani ENF signali, i dati su odgovarajući zaključci.

Šesto poglavlje obuhvata analizu i ekstrakciju značajki ENF signala. Predstavljeni su i objašnjeni različiti parametri koji kvantitativno opisuju ENF signal, i koji utiču na lokacijsku klasifikaciju. Također, kako bi se povećala tačnost klasifikacije izvršen je odabir odgovarajućih statističkih značajki za različite multimedijalne zapise.

Poglavlja sedam i osam opisuju klasifikaciju podataka koristeći mašine vektorske podrške (SVM). Prikazane su osnovne strategije treniranja mašina vektorske podrške, pri čemu su navedeni osnovni parametri koji karakterišu nelinearne klasifikatore. Klasifikacija multimedijalnih zapisa je izvedena korištenjem četiri nelinearna SVM klasifikatora. Na kraju su dati rezultati klasifikacija multimedijalnih zapisa, uz dodatna objašnjenja i odgovarajuće zaključke.

# 2. Frekvencija elektroenergetske mreže

ENF (eng. *Electrical Network Frequency*) je skraćenica za frekvenciju elektroenergetske mreže. Definiše se kao frekvencija opskrbe električnom energijom u distributivnim mrežama [3]. Nominalna vrijednost frekvencije elektroenergetske mreže iznosi 50 ili 60 [Hz], u zavisnosti od geografske lokacije.

Nominalna vrijednost ENF je 60 [Hz] u Sjedinjenim Američkim Državama i većini dijelova Amerike, Tajvanu, Saudijskoj Arabiji i Filipinima. U većini područja Evrope i Azije nominalna vrijednost ENF je 50 [Hz]. Japan koristi dualni standard od 50 i 60 [Hz]. Na slici 2.1. su prikazani svjetski standardi za električnu energiju.



Slika 2.1. Svjetski standardi za električnu energiju [4]

Važno svojstvo ENF je da njena vrijednost osciluje (eng. *fluctuates*) oko nominalne vrijednosti, zbog promjene opterećenja u električnoj mreži. ENF signal se definiše kao promjenljiva vrijednost trenutne frekvencije elektroenergetske mreže.

U kontinentalnoj Evropi navedene fluktuacije utiču na promjenu ENF signala u intervalu od 49.9 [Hz] do 50.1 [Hz]. U Sjedinjenim Američkim Državama fluktuacije ENF signala su u intervalu od 59.9 [Hz] do 60.1 [Hz] [1].

Da bi se osigurala stabilnost elektroenergetske mreže i pravilno funkcionisanje električne opreme, potrebno je kontrolisati mrežu tako da fluktuacije ostanu u blizini nominalne vrijednosti.

Pokazano je da multimedijalni snimci nastali korištenjem uređaja koji su priključeni na mrežu, ili se nalaze u blizini izvora električne energije, mogu sadržavati ENF signal. Razlozi zbog kojih navedeni zapisi sadrže ENF su sljedeći:

- elektromagnetne interferencije,
- akustične vibracije,
- nevidljivo treperenje rasvjete,
- > mehaničke vibracije koje proizvode okolni električni uređaji.

Na slici 2.2. je dat prikaz ENF signala. ENF signal prikazan na slici a) je ekstrahovan iz audio zapisa na osnovu drugog harmonika (120 [Hz]). ENF signal prikazan na slici b) je ekstrahovan iz mrežnog zapisa pri nominalnoj frekvenciji 60 [Hz]. Dakle, uočljivo je da ENF signal ekstrahovan iz audio snimka pokazuje visoku korelaciju sa ENF signalom ekstrahovanim iz snimka električne mreže u odgovarajućem vremenu.



Slika 2.2. a) ENF signal audio zapisa, b) ENF signal mreže [5]

Priroda fluktuacija obuhvaćena u digitalnom zapisu je vrlo slična fluktuacijama u signalu koji je snimljen direktno iz električne mreže u odgovarajućem vremenu. Poređenjem ova dva ENF signala moguće je odrediti vrijeme nastanka snimka. Također, analiza faznog kontinuiteta ENF signala omogućava otkrivanje nedozvoljenog ubacivanja ili uklanjanja isječaka iz audio signala [6].

## 2.1. Analiza ENF signala

Tačna i pouzdana estimacija ENF signala je od najveće važnosti u forenzičkim aplikacijama. Valjanost rezultata zavisi od tačne procjene frekvencije dobivene upotrebom relativno kratkih segmenata zapisa. ENF signali mogu biti različitog kvaliteta za različite snimke. Na primjer, ENF signali sadržani u audio snimcima imaju malu vrijednost omjera signal/šum (eng. *Signal to noise ratio – SNR*) u odnosu na signal zabilježen direktno iz izvora napajanja [7].

Osim toga, određivanje vremena nastanka multimedijalnog snimka bitno zavisi od vremenske rezolucije. Vremenska rezolucija je ograničena trajanjem segmenata (eng. *frames*) korištenih za estimaciju trenutne vrijednosti frekvencije ENF signala. Upotreba kratkih segmenata poboljšava vremensku rezoluciju, ali smanjuje pouzdanost estimacije trenutne frekvencije, odnosno smanjuje frekventnu rezoluciju. Također, ograničena vremenska rezolucija može uticati na sposobnosti forenzičara da analizira moguća falsifikovanja ENF signala.

# 3. Ekstrakcija ENF signala

Metoda autentifikacije bazirana na ENF signalu predstavlja efektivnu i efikasnu forenzičku tehniku za autentifikaciju digitalnih audio snimaka. Navedena metoda je zasnovana na sljedećim pretpostavkama:

- ENF signali su međusobno povezani i vrlo slični u svim tačkama u okviru iste mreže,
- svaka fluktuacija frekvencije se posmatra kao slučajna varijabla, koja se ne ponavlja unutar dugog vremenskog perioda.

Ekstrakcija ENF signala predstavlja preduslov za sve daljnje analize. Osnovne metode za ekstrakciju ENF signala iz digitalnih snimaka se mogu podijeliti na:

**1.** Analize u vremenskom i frekventnom domenu – metode zasnovane na izračunavanju spektrograma signala i poređenju istog sa određenom bazom podataka, ili korištenju Wavelet transformacije sa fleksibilnim prozorom za analizu realnih signala,

2. Analiza u frekventnom domenu – metoda zasnovana na određivanju lokacije frekvencije kojoj odgovara maksimalna amplituda spektra segmenta signala,

*3. Analiza u vremenskom domenu* – metoda zasnovana na mjerenju broja prolazaka signala kroz nulu u vremenskom domenu.

Metode analize u frekventnom domenu koriste kratkotrajnu Fourierovu transformaciju (eng. *short-time Fourier transform - STFT*), koja se primjenjuje na susjedne segmente audio signala ili segmente koji se preklapaju. Važni parametri transformacije su:

- broj uzoraka u okviru posmatranog vremenskog intervala,
- izbor funkcije prozora,
- veličina koraka koja određuje međusobno preklapanje susjednih prozora.

Za analizu signala u frekventnom domenu se koristi i Chirp-Z transformacija (eng. *Chirp Z-transform - CZT*), koja predstavlja generalizaciju diskretne Fourierove transformacije, kao i metode bazirane na svojstvenim vrijednostima matrice kovarijansi podataka [8].

Metode analize u vremenskom domenu određuju frekvenciju na osnovu perioda ENF oscilacija, i primjenom različitih filtera i metoda interpolacije.

Tehnike ekstrakcije ENF signala u vremenskom i frekventnom domenu imaju skoro istu preciznost pod idealnim uvjetima, ali su komplementarne s obzirom na konkretnu primjenu.

Metode analize u vremenskom domenu su se pokazale vrlo korisne za ekstrakciju ENF signala direktno iz snimka mreže (eng. *power line*). Navedenu tehniku koriste distributivne kompanije za snimanje trendova promjene, zbog održavanja ENF signala u dozvoljenim granicama.

Međutim, ova tehnika nije pogodna za izdvajanje ENF signala iz zapisa govora ili muzičkog sadržaja, jer se oslanja na cijeli frekventni spektar šuma prilikom izračunavanja. U te svrhe se koriste tehnike analize u frekventnom domenu. Metode analize u frekventnom domenu se dijele na:

- neparametarske metode,
- parametarske metode.

## 3.1. Neparametarske metode

Neparametarske metode ne pretpostavljaju eksplicitni model podataka. Zasnivaju se na Fourierovoj analizi signala. Neparametarske metode koriste spektrogram i vremenski rekurzivni iterativni adaptivni pristup (eng. *time recursive iterative adaptive approach – TR-IAA*) za estimaciju trenutne frekvencije [7].

#### 3.1.1. Metoda spektrograma

Spektrogram predstavlja jako koristan alat za analizu i vizualizaciju STFT signala. Omogućava lakše određivanje dominantne trenutne frekvencije signala kao funkciju vremena, tako što računa i prikazuje STFT signala.

STFT se može posmatrati kao amplituda Fourierove transformacije dijela signala, primjenom kliznog prozora (eng. *sliding window*) s ciljem pokrivanja cijele funkcije. Vizuelna reprezentacija transformacije je prikazana na slici 3.1.

Broj prozora potrebnih za pokrivanje cijelog signala zavisi od dužine signala N, dužine prozora L i preklapanja M između svakog uzastopnog prozora, i dat je relacijom 3.1.

$$Broj \, prozora = \frac{N-L+M}{M} \tag{3.1}$$

#### Dužina signala = N



Slika 3.1. Koncept STFT primjenom kliznog prozora na signal [6]

Dobiveni rezultat se može posmatrati kao dvodimenzionalna reprezentacija signala, pri čemu su ose frekvencija i vrijeme. Promjenom dužine prozora se direktno utiče na rezoluciju po vremenu i frekvenciji, kako je prikazano na slici 3.2.



Slika 3.2. Poređenje vremenske i frekventne rezolucije: a) bolja vremenska rezolucija, b) bolja frekventna rezolucija) [6]

Na osnovu slike 3.2 moguće je zaključiti sljedeće:

- veća dužina prozora će proizvesti bolju frekventnu rezoluciju zbog povećanja broja uzoraka signala,
- manja dužina prozora će proizvesti bolju vremensku rezoluciju.

Očigledno je da povećanje rezolucije u jednoj domeni uzrokuje smanjenje rezolucije u drugoj domeni. Dakle, osnovni nedostatak STFT je fiksna rezolucija. Problem rezolucije je moguće riješiti korištenjem multirezolucijske analize ili Wavelet transformacije. Navedene metode koriste fleksibilnu dužinu prozora, čime se postiže dobra frekventna rezolucija pri niskim frekvencijama, te dobra vremenska rezolucija pri visokim frekvencijama. U zavisnosti od primjene, potrebno je odabrati adekvatnu metodu koja će zadovoljiti sve zahtjeve.

Nakon što je signal podijeljen na segmente koji se preklapaju, potrebno je odrediti dominantnu trenutnu frekvenciju na osnovu Fourierove analize. Koriste se 2 pristupa:

- Pristup maksimalne energije sa kvadratnom interpolacijom (eng. *Maximum energy approach with quadratic interpolation*),
- Pristup otežane energije (eng. Weighted energy approach).

#### Pristup maksimalne energije sa kvadratnom interpolacijom

Prvi korak ovog pristupa je pronalazak frekvencije koja ima maksimalnu spektralnu snagu za dati segment. Međutim, ukoliko bi se ova frekvencija direktno odabrala kao frekvencija segmenta, došlo bi do gubitka preciznosti. Razlog tome jeste što se spektrogram izračunava za konačan broj tačaka (frekvencija). Može se desiti da stvarna frekvencija sa maksimalnom energijom ne bude u navedenom skupu frekvencija.

Da bi se poboljšala preciznost estimacije moguće je povećati broj tačaka Fourierove transformacije, što dovodi do veće računske kompleksnosti. Alternativni pristup je korištenje kvadratne interpolacije. Kvadratna interpolacija podešava PSD (eng. *power spectral density*) vrijednosti tačaka koje pripadaju opsegu oko stvarne frekvencije sa maksimalnom energijom [7].

Proračunata spektralna gustina snage (PSD) svakog okvira je funkcija diskretnih frekvencija. Ukoliko se indeks frekvencije sa maksimalnom energijom označi sa  $k_{max}$ , onda je moguće definisati koordinatni sistem sa centrom u ( $k_{max}$ , 0). Neka je y(k) vrijednost logaritma amplitude PSD. Koristeći tri tačke spektralne gustine snage, i to  $k_{max-1}$ ,  $k_{max}$ , i  $k_{max+1}$ , moguće je izvršiti kvadratnu interpolaciju prema formuli:

$$y(k) = a(k-p)^2 + b$$
 (3.2)

Rješavanjem jednačine za vrh parabole *p*, dobiva se izraz:

$$p = \frac{1}{2} \frac{y(k_{max-1}) - y(k_{max+1})}{y(k_{max-1}) - 2y(k_{max}) + y(k_{max+1})}$$
(3.3)

gdje je y(k) definisano kao:

$$y(k) = 20\log_{10}|PSD(k)|$$
(3.4)

Lokacija estimiranog vrha, koja odgovara indeksu stvarne frekvencije je:

$$k_t = k_{max} + p \tag{3.5}$$

Estimirana frekvencija koja odgovara indeksu  $k_t$  je:

$$f_t = \frac{k_t f_s}{N} \tag{3.6}$$

gdje je  $f_s$  frekvencija uzorkovanja, a N broj tačaka Fourierove transformacije korištenih za računanje spektrograma. Na slici 3.3. je dat grafički prikaz prethodno opisane metode.



Slika 3.3. Grafički prikaz kvadratne interpolacije [9]

Nedostatak ovog pristupa je podložnost neprihvatljivim (ekstremnim) vrijednostima. Ako je maksimalna energija daleko do nominalne frekvencije zbog aditivnog šuma ili smetnji, estimacija će biti pogrešna [7].

#### Pristup otežane energije

Pristup otežane energije koristi dodatne informacije u vidu nominalne frekvencije. Rezultat estimacije frekvencije je u ovom slučaju robustan na ekstremne vrijednosti frekvencije [7].

Estimirana frekvencija F(n), za *n*-ti segment, se zasniva na računanju otežanih vrijednosti frekvencija oko nominalne vrijednosti prema formuli:

$$F(n) = \frac{\sum_{l=L_1}^{L_2} f(n,l) |S(n,l)|}{\sum_{l=L_1}^{L_2} |S(n,l)|}$$
(3.7)

f(n, l) i S(n, l) su frekvencija i energija *n*-tog segmenta *l*-tog indeksa frekvencije spektrograma snimljenog signala, respektivno.

Granice sume se računaju kao:

$$L_{1} = \left[\frac{(f_{ENF} - 0.5)N_{F}}{f_{s}}\right] \qquad \qquad L_{2} = \left[\frac{(f_{ENF} + 0.5)N_{F}}{f_{s}}\right] \qquad (3.8)$$

 $N_F$  je broj tačaka Fourierove transformacije za računanje spektrograma, a  $f_s$  je frekvencija uzorkovanja.  $f_{ENF}$  predstavlja frekvenciju sa maksimalnom energijom trenutnog okvira.

Prethodno opisana metoda daje precizniju procjenu trenutne frekvencije za dati ENF signal u odnosu na metodu maksimalne energije.

#### 3.1.2. Vremenski rekurzivni iterativni adaptivni algoritam

Vremenski rekurzivni iterativni adaptivni algoritam (TR-IAA) pripada klasi neparametarskih metoda za estimaciju frekvencije. Navedeni algoritam vrši spektralnu procjenu vremenskog segmenta minimiziranjem kvadratne funkcije cilja, koristeći otežanu formulaciju metode najmanjih kvadrata (eng. *weighted least squares*).

TR-IAA predstavlja iterativnu tehniku u kojoj se konvergencija postiže nakon 10 do 15 iteracija. Spektralna procjena se na svakoj iteraciji inicijalizira na vrijednost spektralne procjene iz prethodnog vremenskog segmenta. Nakon konvergencije spektralne procjene, za estimaciju frekvencije se koristi kvadratna interpolacija koja je slična interpolaciji u prvoj opisanoj metodi spektrograma.

TR-IAA metoda je računski zahtjevnija od metode na bazi spektrograma. Međutim, dokazano je da TR-IAA obezbjeđuje donekle bolju estimaciju frekvencije u odnosu na pristup koji se zasniva na spektrogramu, ukoliko je trajanje segmenta od 20 do 30 sekundi [7].

Budući da se razmatraju segmenti kratkog trajanja, kao i zbog veće računske zahtjevnosti TR-IAA algoritma, koristiti će se metode bazirane na spektrogramu.

## **3.2. Parametarske metode**

Parametarske metode pretpostavljaju eksplicitan model signala i osnovnog šuma. Zbog eksplicitne pretpostavke o modelu, rezultati dobiveni ovim pristupom imaju veću preciznost u odnosu na neparametarske metode [7].

Metode podprostora pripadaju klasi najčešće korištenih parametarskih metoda estimacije frekvencije jako zašumljenih sinusoidalnih signala. Navedene metode se prvenstveno koriste u aplikacijama gdje je trajanje signala malo [1].

ENF signali u multimedijalnim zapisima često sadrže visok nivo šuma, dok je dinamički opseg varijacija frekvencije mali. Metode podprostora u tim slučajevima su jako korisne, jer se dobivaju preciznije procjene frekvencije ENF signala.

Dvije najpoznatije metode podprostora su:

- MUSIC (eng. Multiple Signal Component) višestruke komponente signala, i
- ESPRIT (eng. *Estimation of Signal Parameters via Rotational Invariance Techniques*)

   estimacija parametara signala koristeći tehnike rotacione invarijantnosti.

#### **MUSIC** algoritam

MUSIC algoritam je zasnovan na procjeni osnovnih parametara signala iz određenih zapažanja. Navedena metoda poboljšava jednostavni Pisarenko algoritam [1] i estimira frekventne komponente signala, koji se sastoji od poznatog broja sinusoida i bijelog šuma [9].

Algoritam se oslanja na osobinu ortogonalnosti podprostora sinusnog signala i podprostora šuma. Također, proces estimacije frekvencije sinusnog signala koristi manji broj tačaka u odnosu na metode bazirane na spektrogramu, što značajno poboljšava rezoluciju.

Za estimaciju frekvencija signala koristi se analiza svojstvenog prostora (eng. eigenspace analysis). Metoda vrši estimaciju autokorelacione matrice  $R_x$  dimenzija  $[M \ x \ M]$  datog signala x(n), koji se sastoji od p kompleksnih sinusoida sa bijelim Gausovim šumom. Svojstveni vektori, kojima odgovara p najvećih svojstvenih vrijednosti matrice  $R_x$ , razapinju podprostor signala. Preostali svojstveni vektori razapinju podprostor šuma. Nakon procjene svojstvenih vektora matrice  $R_x$ , funkcija estimacije frekvencije MUSIC algoritma je data izrazom:

$$P_{MUSIC}(e^{j\omega}) = \frac{1}{\sum_{i=p+1}^{M} |e^{H}v_{i}|^{2}}$$
(3.9)

gdje je  $\boldsymbol{e} = \left[1 e^{j\omega} \dots e^{j(M-1)\omega}\right]^T$  vektor kolona, a  $v_i$  predstavlja svojstveni vektor podprostora šuma. Vrijednosti  $\omega$  predstavljaju estimirane frekvencije prisutne u sinusnom signalu x(n).

#### **ESPRIT** algoritam

Estimacija parametara signala koristeći tehnike invarijantne rotacije je vrlo slična MUSIC metodi. Suštinske razlike između MUSIC i ESPRIT algoritma su:

- ESPRIT algoritam koristi podprostor signala, a MUSIC algoritam podprostor šuma,
- ESPRIT algoritam estimira podprostor signala na osnovu matrice podataka, a MUSIC algoritam eksplicitno računa korelacionu matricu.

ESPRIT algoritam, slično kao i MUSIC, obezbjeđuje robusnu procjenu frekvencije signala koristeći manji broj tačaka u odnosu na metode bazirane na spektrogramu.

U pogavlju 3.1. i 3.2. su predstavljene metode koje se koriste za ekstrakciju ENF signala. Mnoga naučna istraživanja su pokazala da metode zasnovane na spektrogramu daju vrlo dobre rezultate s obzirom na računsku kompleksnost. Dakle, potrebno je manje vremena i memorijskih resursa za estimaciju frekvencije ukoliko se koriste metode spektrograma, u odnosu na ESPRIT i MUSIC algoritme.

Zbog navedenih prednosti, za proces ekstrakcije ENF signala iz audio snimaka i snimaka mreže će se koristiti metode zasnovane na spektrogramu. Implementacije metode maksimalne energije sa kvadratnom interpolacijom i metode otežane energije su prikazane u prilogu A i prilogu B na kraju rada. Navedene metode su implementirane u programskom paketu Matlab.

# 4. Ekstrakcija ENF signala iz signala poznate frekvencije

Implementirane metode bazirane na spektrogramu je potrebno testirati na određenom signalu poznate frekvencije, kako bi se odredila njihova tačnost. Testni signal je oblika sinusoide, amplitude 1 [V] i frekvencije koja se mijenja u opsegu od 49.8 [Hz] do 50.2 [Hz].

Kako bi se ispitao uticaj šuma na estimaciju frekvencije ENF signala, testni signal je zašumljen. Na slici 4.1. je prikazan izgled originalnog i zašumljenog signala koji se koristio za testiranje metoda, kao i stvarna promjena frekvencije signala.



Slika 4.1. a) prikaz originalnog i zašumljenog signala, b) promjene frekvencije

Za metode spektrograma je vrlo bitna dužina prozora L, koja direktno utiče na rezoluciju po vremenu i frekvenciji.

Veća dužina prozora će proizvesti bolju frekventnu rezoluciju zbog povećanja broja uzoraka signala. Manja dužina prozora će proizvesti bolju vremensku rezoluciju.

Testirana su 3 slučaja, za različite vrijednosti L:

• L=16384 uzoraka – odgovara trajanju od 16 [s],

- L=32768 uzoraka odgovara trajanju od 32 [s],
- L=65536 uzoraka odgovara trajanju od 64 [s].

Odabrano je da preklapanje između uzastopnih prozora bude jednako polovini vrijednosti L.

### 4.1. Testni signal bez šuma

Na slikama 4.2, 4.3, 4.4. su prikazane estimirane vrijednosti frekvencije korištenjem metoda spektrograma za različite dužine prozora.



Slika 4.2. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 16 [s]



Slika 4.3. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 32 [s]



Slika 4.4. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 64 [s]

Na osnovu prethodno prikazanih estimacija pokazano je da metod otežane energije daje tačniju procjenu trenutne frekvencije za dati ENF signal u odnosu na metod maksimalne energije. Također, što je dužina prozora veća, dobiva se tačnija procjena ENF signala i greške estimacije postaju sve manje. Dakle, frekventna rezolucija se poboljšava.

Međutim, veća dužina prozora ima za posljedicu manji broj uzoraka ENF signala, čime se smanjuje vremenska rezolucija.

U tabeli 4.1. su date srednje vrijednosti greške  $\bar{e}$ , i vrijednosti koeficijenata korelacije za signale dobivene metodama spektrograma. Koeficijent korelacije se definiše kao kvantitativna mjera povezanosti, odnosno statistički odnos dvije ili više slučajnih varijabli.

Metod	Trajanje [s]	ē	Koeficijent korelacije
Maksimalna energija	16	0.0091	0.9945
	32	0.0072	0.9823
	64	0.0049	0.9812
Otežana energija	16	0.0074	0.9969
	32	0.0051	0.9946
	64	0.0054	0.9927

Tabela 4.1. Poređenje metoda spektrograma korištenjem karakterističnih vrijednosti

Na osnovu tabele 4.1. pokazano je da se najmanja vrijednost greške i najbolje poklapanje dobiva ukoliko trajanje iznosi 32 [s], odnosno za L=32768 uzoraka.

## 4.2. Testni signal sa šumom

Ukoliko originalni signal sadrži šum maksimalne amplitude 0.5 sa uniformnom raspodjelom, testiranje je pokazalo da ne dolazi do odstupanja u estimaciji ENF signala. Na slici 4.5. su prikazane estimacije ENF signala za različite dužine prozora L.

Za estimacije prikazane na slici 4.5 su dobiveni identični rezultati dati u tabeli 4.1, a koji se odnose na srednju vrijednost greške i vrijednosti koeficijenata korelacije.



Slika 4.5. Estimacije ENF signala iz zašumljenog signala za a) trajanje=16 [s], b) trajanje=32 [s], c) trajanje=64 [s]

Na osnovu prethodno izloženog se može zaključiti da metoda otežane energije daje tačnije estimacije frekvencije. Također, najprihvatljiviji rezultati su dobiveni kada je dužina prozora iznosila 32768 uzoraka, odnosno za trajanje od 32 [s]. Zbog toga će se za ekstrakciju ENF signala iz snimaka mreže i audio snimaka koristiti metoda otežane energije uz prethodno navedenu dužinu prozora.

# 5. Opis baze multimedijalnih zapisa

Baza multimedijalnih zapisa<sup>1</sup> se sastoji od skupa zapisa za treniranje klasifikatora i skupa zapisa za testiranje klasifikatora. Snimci su pohranjeni u obliku .wav datoteka, pri čemu frekvencija uzorkovanja signala iznosi 1 [kHz].

Skup zapisa za treniranje klasifikatora sadrži audio i mrežne zapise za ukupno 9 elektroenergetskih mreža, koje su označene slovima od A do I, respektivno. Na slici 5.1. je prikazan grafik ukupnog broja snimaka za svaku od mreža.

Skup zapisa za testiranje klasifikatora sadrži ukupno 50 snimaka, za koje nije poznato da li pripadaju skupini audio snimaka ili snimaka mreže. Također, za navedene snimke je poznato kojoj mreži pripadaju, kako bi se mogla utvrditi tačnost klasifikatora.



Slika 5.1. Ukupan broj zapisa skupa za treniranje klasifikatora za svaku od mreža

Analizom frekventnog spektra snimaka moguće je jednostavno odrediti nominalnu vrijednost frekvencije za svaku od mreža. U tabeli 5.1. su prikazane određene frekvencije mreža.

<sup>&</sup>lt;sup>1</sup> Za realizaciju završnog rada koristiti će se baza podataka preuzeta iz [10].

Mreža	Nominalna frekvencija [Hz]	Mreža	Nominalna frekvencija [Hz]
Α	60	F	50
В	50	G	50
С	60	Н	50
D	50	Ι	60
E	50		

#### Tabela 5.1. Nominalne frekvencije mreža

Na osnovu prethodno izloženog, prvi korak neophodan za gradnju sistema klasifikacije jeste ekstrakcija ENF signala iz snimaka koji čine skup za treniranje klasifikatora.

## 5.1. Ekstrakcija ENF signala iz audio snimaka i snimaka mreže

Audio snimci i snimci mreže, sadržani u bazi podataka za treniranje klasifikatora, imaju različita trajanja. Kako bi ENF signali imali jednak broj uzoraka, odnosno istu dužinu trajanja, potrebno je ograničiti trajanja navedenih zapisa.

Empirijski je odabrano da svaki snimak ima trajanje od 10 minuta. Na taj način je jedan duži zapis podijeljen na više kraćih zapisa u trajanju od 10 minuta. Time je povećan skup podataka za treniranje klasifikatora.

Princip rada algoritma za ekstrakciju ENF signala je prikazan na slici 5.2. Prvi korak u algoritmu je učitavanje odgovarajućeg zapisa. Drugi korak podrazumijeva određivanje snage učitanog signala, s ciljem otkrivanja da li isti pripada skupini audio snimaka ili snimaka mreže.

Snaga signala se određuje iz relacije:

$$P = \frac{1}{N} \sum_{n=0}^{N-1} x^2[n]$$
(5.1)

Empirijski je određeno da signal pripada klasi snimaka mreže ukoliko je njegova snaga veća od 0.01 [W]. U suprotnom, učitani signal će biti klasifikovan kao audio snimak.

Treći korak algoritma uključuje određivanje nominalne frekvencije signala, a koja može biti 50 ili 60 [Hz]. Također, u zavisnosti od toga da li je u pitanju audio snimak ili snimak mreže, koriste se različiti pristupi za određivanje nominalne frekvencije.



Slika 5.2. Princip rada algoritma za ekstrakciju ENF signala

Audio snimci imaju mali odnos signal/šum (eng. *Signal to Noise ratio – SNR*), što znači da sadrže više šuma, nego što je to slučaj sa snimcima mreže. Na slici 5.3. su prikazani spektrogrami i frekventni spektri snimaka, koji potvrđuju prethodno navedeno.



Slika 5.3. Spektrogram i frekventni spektar snimka mreže (a i b), spektrogram i frekventni spektar audio snimka (c i d)

#### Određivanje nominalne frekvencije audio snimaka

Prvobitni pristup se bazirao na računanju srednjih vrijednosti amplituda frekventnog spektra na 50, 100, 150 i 200 [Hz], kao i na 60, 120, 180 i 240 [Hz]. Dobivene srednje vrijednosti su zatim upoređene, i ona koja je bila veća je određivala nominalnu frekvenciju signala. Međutim, utvrđeno je da je ova metoda jako osjetljiva na šumove prisutne u signalu.

S ciljem smanjenja uticaja šuma i određivanja nominalne frekvencije signala, poboljšano je računanje srednjih vrijednosti amplituda frekventnog spektra. Da bi se odredila maksimalna amplituda oko frekvencije f, definiše se parametar h:

$$h = \max(f - d_1, f + d_1) - \frac{mean(f - d_1 - d_2, f - d_1) + mean(f + d_1, f + d_1 + d_2)}{2}$$
(5.2)

gdje je:

f – frekvencija od interesa, a  $d_1$  i  $d_2$  - vrijednosti koje definišu opseg promjene frekvencije f.

Funkcija *max* kao rezultat daje maksimalnu vrijednost amplitude u opsegu od  $f - d_1$  do  $f + d_1$ . Funkcija *mean* kao rezultat daje srednju vrijednost amplituda u opsezima  $[f - d_1 - d_2, f - d_1]$  i  $[f + d_1, f + d_1 + d_2]$ .

Parametar *h* predstavlja vrijednost amplitude na frekvenciji *f* u odnosu na frekvencije koje je okružuju. Navedeni parametar je izračunat za frekvencije 50/100/150/200 [Hz], kao i 60/120/180/240 [Hz]. Zatim su određene i upoređene srednje vrijednosti amplituda. Veća srednja vrijednost je određivala nominalnu frekvenciju signala (50 ili 60 [Hz]).

#### Određivanje nominalne frekvencije snimaka mreže

Sa slike 5.3. je moguće uočiti da snimci mreže imaju jako malo šuma (ili skoro nikako). Iz tog razloga je mnogo lakše odrediti nominalnu frekvenciju signala. Dakle, prvo se odredi maksimalna vrijednost amplitude frekventnog spektra, kao i frekvencija  $f_{max}$  koja joj odgovara. Nakon toga se odredi kojoj vrijednosti je  $f_{max}$  najbliža, 50 [Hz] ili 60 [Hz], što određuje nominalnu frekvenciju signala.

Nakon što je određena nominalna frekvencija, pristupa se ekstrakciji ENF signala. Ekstrakcija ENF signala je zasnovana na metodi otežane energije. Učitani snimak (signal) se dijeli na preklapajuće okvire. Parametri koji definišu STFT transformaciju su sljedeći:

- dužina signala N trajanje = 10 [min] = 600 [s],
- dužina prozora L trajanje = 32 [s],
- preklapanje M = L/2.

ENF signali ekstrahovani iz audio snimaka i snimaka mreže čija nominalna frekvencija iznosi 50 [Hz], odnosno 60 [Hz] su prikazani na slikama 5.4 i 5.5, respektivno. Za svaku mrežu je prikazan po jedan primjer, slučajno odabran iz baze podataka.

Uočljivo je da iste mreže imaju različite oblike ENF signala. Razlog tome jeste što su korišteni zapisi snimani u različitim vremenskim trenucima. Međutim, bitno je naglasiti da i pored različitih valnih oblika ENF signali zadržavaju karakteristike mreže iz koje potiču, bez obzira na vremenske trenutke snimanja.





Slika 5.4. Izgled ENF signala za mreže nominalne frekvencije 50 [Hz]



Slika 5.5. Izgled ENF signala za mreže nominalne frekvencije 60 [Hz]

Implementacije funkcija za učitavanje i određivanje snage signala, kao i određivanje nominalne frekvencije audio snimaka i snimaka mreže su prikazane u prilozima C, D i E na kraju rada. Navedene funkcije su implementirane u programskom paketu Matlab.

# 6. Analiza i ekstrakcija značajki ENF signala

ENF signal nosi mnoge informacije o mreži iz koje potiče. Pokazano je da ENF signal bitno ovisi o potrošnji energije unutar mreže i mehanizmu kontrole koji se koristi, pa se zbog toga može posmatrati kao slučajni proces [1].

Kako bi se izgradio sistem klasifikacije mreže, potrebno je izvršiti detaljnu analizu i ekstrakciju statističkih značajki ENF signala (eng. *feature extraction*). Dobiveni statistički parametri u opštem slučaju kvantitativno opisuju ENF signal i njegove promjene.

## 6.1. Vremenski domen ENF signala

Tri osnovne značajke koje karakterišu ENF signal u vremenskom domenu su:

- srednja vrijednost signala,
- 🖊 varijansa signala,
- ↓ dinamički opseg (eng. *dynamic range*) signala.

Određivanje srednje vrijednosti ENF signala je korisno zbog lakše identifikacije da li snimljeni zapis pripada mrežama nominalne frekvencije 50 ili 60 [Hz]. Međutim, interesantno je da se čak i signali sa istom nominalnom frekvencijom mogu razlikovati po iznosu srednje vrijednosti ENF signala.

Varijansa je drugi značajan parametar koji karakteriše prirodu odstupanja frekvencije mreže. Također, varijansa daje informacije o tome koliko dugo je frekvencija odstupala od nominalne frekvencije.

Dinamički opseg opisuje granice u kojima se kreće ENF signal, i predstavlja razliku minimalne i maksimalne vrijednosti ENF signala. Analizom je utvrđeno da neke od mreža iz baze ENF signala imaju mali dinamički opseg, kao što je mreža A, dok druge imaju veliki opseg promjene frekvencije, kao što je mreža B.

Navedene tri značajke predstavljaju jako dobre kandidate za lokacijsku klasifikaciju [11].

## 6.2. Wavelet analiza ENF signala

Wavelet analiza predstavlja relativno novu metodu u analizi signala, i pripada klasi generalizovanih metoda multirezolucijske analize. Wavelet transformacija se može posmatrati kao dekompozicija signala u skup baznih funkcija (waveleta) [12].

Diskretna Wavelet transformacija (eng. *Discrete Wavelet Transform – DWT*) je jako pogodna za multirezolucijsku analizu, i koristi se za razlaganje signala na frekventne komponente. DWT razlaže više frekventne komponente signala sa dobrom vremenskom rezolucijom, ali grubom frekventnom rezolucijom, dok za niske frekventne komponente signala vrijedi obratno. Dakle, signal se rastavlja na aproksimacije koje sadrže niske frekventne komponente i detalje sa višim frekvencijama.

Primjena multirezolucijske analize i korištenje diskretne Wavelet transformacije omogućava dobivanje potencijalnih statističkih značajki koje opsuju ENF signal [11].

U ovom slučaju se koristi wavelet dekompozicija signala na L-nivoa (eng. *L-level wavelet decomposition*), gdje svaki nivo daje koeficijente aproksimacija i detalja signala, kako je prikazano na slici 6.1.



*Slika 6.1. Struktura dekompozicije signala na 3 nivoa (L=3)* 

Varijansa koeficijenata detalja  $D_1$ ,  $D_2$  i  $D_3$ , kao i varijansa koeficijenta aproksimacije  $A_3$  su odabrani kao statistički parametri Wavelet analize.
### 6.3. Autoregresivni (AR) model ENF signala

U oblasti statistike i obrade signala, autoregresivni model (eng. *Auto Regressive model*) ili AR model se koristi za predstavljanje slučajnih procesa [13]. AR model definiše linearnu zavisnost između trenutne vrijednosti izlazne veličine sa njenim prethodnim vrijednostima.

Jedan od predloženih načina modeliranja ENF signala jeste upravo preko AR modela, što je detaljno opisano u [1] i [6]. Dakle, ENF signal je moguće predstaviti preko AR modela drugog reda:

$$f(n) = a_1 f(n-1) + a_2 f(n-2) + v(n)$$
(6.1)

gdje  $a_1$  i  $a_2$  predstavljaju AR koeficijente, a v(n) bijeli šum nekorelisan sa f(n). U literaturi se v(n) naziva procesom (signalom) inovacije (eng. *innovation process*).

AR koeficijenti  $a_1$  i  $a_2$ , i varijansa signala inovacije v(n) predstavljaju dodatna tri parametra koja će se koristiti za opis ENF signala. AR parametri nose informaciju o linearnoj vezi između uzoraka signala f(n), a varijansa inovacije signala v(n) je pokazatelj koliko se dobro ENF signal uklapa u AR(2) model.

Navedeni parametri imaju potencijal da pomognu u razlikovanju ENF signala u smislu koliko dobro se oni mogu uklopiti u odabrani AR(2) model i na koji način.

### 6.4. Autoregresivni model sa pokretnom srednjom vrijednošću (ARMA)

Autoregresivni model sa pokretnom srednjom vrijednošću (eng. *Auto Regressive Moving Average model*) je generalizirani model koji predstavlja kombinaciju AR i MA (eng. *Moving Average*) modela. AR i ARMA modeli imaju široku primjenu u oblastima analize signala i identifikacije sistema. Zbog prethodno navedenog, ENF signal će se također predstaviti korištenjem ARMA modela. ARMA model je opisan diferentnom jednačinom:

$$\sum_{k=0}^{N} a_k g[n-k] = \sum_{k=0}^{M} b_k f[n-k]$$
(6.2)

gdje je f[n] ulaz u model, g[n] izlaz modela, a  $a_k$  i  $b_k$  su realni konstantni koeficijenti [13]. Izlaz modela predstavlja linearnu kombinaciju sadašnje i prethodnih vrijednosti ulaza, i prethodnih vrijednosti izlaza. Parametri N i M određuju red diferentne jednačine. Odabrano je da je N=M=3. Na osnovu odabranih parametara proračunati su svi koeficijenti ARMA modela za sve ENF signale, kako bi se izdvojili parametri koji pozitivno utiču na separabilnost mreža. Slika 6.2. prikazuje separabilnost mreža nominalne frekvencije 50 [Hz] ukoliko se koriste navedeni parametri. Očigledno je da koeficijenti  $b_0$ ,  $b_1$ ,  $b_2$  i  $b_3$  doprinose separaciji pojedinih mreža, što nije slučaj sa koeficijentima  $a_1$ ,  $a_2$  i  $a_3$ .



Slika 6.2. Separacija mreža nominalne frekvencije 50 [Hz] korištenjem različitih parametara ARMA modela

Zbog prethodno navedenog se koeficijenti  $b_0$ ,  $b_1$ ,  $b_2$  i  $b_3$  uzimaju kao dodatna četiri parametra za opis ENF signala. Koeficijenti  $a_0$ ,  $a_1$ ,  $a_2$  i  $a_3$  nisu uzeti kao parametri jer ne doprinose poboljšanju klasifikacije ENF signala.

### 6.5. Dodatni parametri za opis ENF signala

Posljednja tri parametra koja će se koristiti u svrhu klasifikacije ENF signala su:

- procenat ekstrema ENF signala za svaki ekstrahovani ENF signal je određen broj lokalnih minimuma i maksimuma podijeljen sa dužinom ENF signala,
- odnos amplituda prvog i trećeg harmonika signala  $A_{f1}/A_{f3}$ ,
- vršni faktor signala (eng. *Crest factor- CF*) predstavlja odnos vršne i efektivne vrijednosti signala, i koristi se za procjenu izobličenja signala.

Utvrđeno je da navedena tri parametra doprinose separabilnosti mreža, kako je prikazano na slici 6.3.



Slika 6.3. Separacija mreža nominalne frekvencije 50 [Hz] korištenjem dodatnih parametara

U tabeli 6.1. su prikazane statističke značajke koje se koriste za lokacijsku klasifikaciju snimljenih zapisa. Operator logaritmiranja je primjenjen na određene parametre s ciljem poboljšanja separabilnosti između njihovih konačnih vrijednosti. Ekstrakcija statističkih značajki je izvršena iz ENF signala koji sadrže ukupno 35 uzoraka.

### 6.6. Normalizacija statističkih značajki

Inteligentne analize uključuju proces transformacije podataka na način da se podaci transformišu u forme pogodne za dalja procesiranja. Normalizacija podataka predstavlja jedan od procesa transformacije i koristi se za skaliranje atributa podataka u manje specifične opsege, kao što su -1.0 do 1.0 ili 0 do 1.0 [14].

Indeks	Parametar
1	Srednja vrijednost ENF signala
2	log(varijansa) ENF signala
3	log(dinamički opseg) ENF signala
4	log(varijansa) aproksimacije nakon L-nivoa wavelet analize (L=3)
5-7	log(varijansa) L-nivoa detalja signala nakon L-nivoa wavelet analize (L=3)
8-9	Koeficijenti $a_1$ i $a_2$ AR(2) modela
10	log(varijansa) signala inovacije $v(n)$ nakon AR(2) modeliranja
11 - 14	Koeficijenti $b_0$ , $b_1$ , $b_2$ i $b_3$ ARMA modela
15	Broj ekstrema ENF signala
16	Odnos $\overline{A_{f1}/A_{f3}}$
17	Vršni faktor <i>CF</i>

Tabela 6.1. Predložene statističke značajke ENF signala

U tabeli 6.1. su prikazani statistički parametri ENF signala koje je potrebno normalizirati prema odgovarajućoj linearnoj skali, kako bi svi podaci imali ravnopravan uticaj na klasifikaciju signala. Odabrana je *z*-score normalizacija, gdje se vrijednosti odgovarajućeg parametra p normaliziraju prema njegovoj srednjoj vrijednosti  $\mu$  i standardnoj devijaciji  $\sigma$ .

Dakle, k-ta vrijednost parametra (značajke) p u skupu za treniranje je normalizovana na osnovu ostalih vrijednosti na poziciji k prema relacijama:

$$\mu_k = \frac{1}{N} \sum_{i=1}^{N} p_i[k]$$
(6.3)

$$\sigma_k^2 = \frac{1}{N-1} \sum_{i=1}^N (p_i[k] - \mu_k)^2$$
(6.4)

$$p_k'[k] = \frac{p_i[k] - \mu_k}{\sigma_k} \tag{6.5}$$

gdje je N ukupan broj primjeraka trening skupa.

Proces normalizacije se ponavlja za k=1, 2, ..., 17. Normalizovane vrijednosti parametara su pohranjene i iskorištene za normalizaciju testnog skupa podataka.

## 6.7. Prikaz statističkih značajki

Izdvojene statističke značajke različitih mreža su prikazane na slikama 6.4 i 6.5. Slika 6.4. prikazuje sve podatke iz skupa za treniranje klasifikatora.



Slika 6.4. Prikaz cjelokupnog normalizovanog skupa podataka za treniranje

Može se uočiti da tačke koje pripadaju istoj mreži (50 ili 60 [Hz]) formiraju klastere, čiji su centri generalno odvojeni od centara drugih klastera. Klaster se definiše kao skup entiteta koji su slični, a nisu slični entitetima iz različitih klastera. [14].

Na slici 6.5.a su prikazani klasteri mreža A, C i I, čija nominalna frekvencija iznosi 60 [Hz]. Vidljivo je da između formiranih klastera postoje manja preklapanja. Na slikama 6.5.b i 6.5.c su prikazani klasteri mreža čija nominalna frekvencija iznosi 50 [Hz].

Mreža D formira klaster koji ima veliko preklapanje sa mrežama E i G. S druge strane, klasteri mreža B, F i H skoro da i nemaju međusobnog preklapanja. Slika 6.5.c ukazuje da je moguće koristiti linearni klasifikator za identifikaciju mreža poput B, F i H. Međutim, s obzirom na preklapajuću prirodu drugih klastera bolje je izgraditi nelinearni klasifikator za prepoznavanje lokacije snimanja. Nelinearni klasifikator će imati veću šansu da pravilno razdvoji podatke sa različitih lokacija.

Implementacije funkcija za izdvajanje statističkih značajki i normalizaciju podataka su prikazane u prilozima F i G na kraju rada. Navedene funkcije su implementirane u programskom paketu Matlab.





*Slika 6.5. Normalizirane vrijednosti statističkih značajki za 60 [Hz] mreže (a) i 50 [Hz] mreže (b i c)* 

### 6.8. Odabir statističkih značajki

U prethodnom poglavlju su prikazane potencijalne statističke značajke koje na odgovarajući način opisuju ENF signale. Međutim, eksperimentalno je utvrđeno da korištenje istih parametara različito doprinosti separaciji mreža. Zbog toga je potrebno odabrati statističke značajke koje vrše najbolje razdvajanje mreža kako bi se ostvarila veća tačnost klasifikacije.

Proveden je niz eksperimenata za različite tipove nominalne frekvencije mreže. Slika 6.6 prikazuje separabilnost 50 [Hz] mreža ukoliko se kao parametri koriste srednja vrijednost ENF signala, opseg ENF signala i koeficijent detalja  $D_1$ . Očigledno je da navedeni parametri doprinose razdvajanju mreže B i mreže H od preostalih mreža.



Slika 6.6. Prikaz separabilnosti mreže B i mreže H u odnosu na preostale mreže

Za razliku od mreže B i mreže H, preostale mreže imaju jako velika preklapanja. Zbog toga je potrebno pronaći statističke značajke koje će omogućiti razlikovanje mreža D, E, F i G. Utvrđeno je da vršni faktor *CF*, koeficijenti detalja  $D_1$  i  $D_2$ , koeficijent  $b_0$  i odnos amplituda prvog i trećeg harmonika pozitivno utiču na razdvajanje 50 [Hz] mreža, kako je prikazano na slici 6.7.



Slika 6.7. Separabilnost 50 [Hz] mreža korištenjem a) koeficijenata  $D_1$ ,  $D_2$  i vršnog faktora, b) koeficijenta  $b_0$ , odnosa  $f_1/f_3$  i vršnog faktora

Elektroenergetske mreže nominalne frekvencije 60 [Hz] su jako slične po karakteristikama, što negativno utiče na separabilnost istih. Kako bi se riješio problem međusobnog preklapanja, eksperimentalno su određeni parametri koji omogućavaju razdvajanje mreža A, C i I, što je prikazano na slici 6.8.



b)

38



*Slika 6.8.* Separabilnost 60 [Hz] mreža korištenjem a) koeficijenta  $D_1$ , odnosa  $f_1/f_3$  i broja ekstrema, b) koeficijenata  $D_1$ ,  $b_2$  i broja ekstrema, c) koeficijenata  $D_1$ ,  $a_2$  i vršnog faktora

Slike 6.6, 6.7 i 6.8 prikazuju samo dio ispitanih slučajeva. Preostali eksperimenti su utvrdili da je potrebno koristiti sljedeće statističke značajke u ovisnosti od nominalne frekvencije mreže:

- 50 [Hz] mreže: srednja vrijednost ENF signala, opseg ENF signala, koeficijenti detalja D<sub>1</sub>, D<sub>2</sub> i D<sub>3</sub>, parametri AR(2) modela, koeficijenti b<sub>0</sub>, b<sub>1</sub> i b<sub>3</sub> ARMA modela, procenat ekstrema, odnos amplituda prvog i trećeg harmonika i vršni faktor,
- 60 [Hz] mreže: srednja vrijednost ENF signala, varijansa ENF signala, opseg ENF signala, koeficijenti aproksimacije i detalja A<sub>1</sub>, D<sub>1</sub>, D<sub>2</sub> i D<sub>3</sub>, koeficijenti a<sub>1</sub> i a<sub>2</sub> AR(2) modela, koeficijenti b<sub>0</sub>, b<sub>1</sub>, b<sub>2</sub> i b<sub>3</sub> ARMA modela, procenat ekstrema, odnos amplituda prvog i trećeg harmonika i vršni faktor.

U zavisnosti od nominalne frekvencije zapisa, odabrani parametri će se koristiti za klasifikaciju istih.

## 7. Sistem mašinskog učenja

Mašinsko učenje pripada oblasti vještačke inteligencije i ima za cilj konstruisanje algoritama i računarskih sistema koji su sposobni da se adaptiraju i uče na bazi iskustva.

Ideja mašinskog učenja je nastojanje da se razvije program koji je u stanju da se automatski poboljšava sa iskustvom [15]. Postoji nekoliko vrsta mašinskog učenja:

- nadzirano učenje (eng. Supervised learning),
- nenadzirano učenje (eng. Unsupervised learning),
- pojačano učenje (eng. Reinforcement learning).

U okviru rada je potrebno izgraditi sistem nadziranog učenja, čiji zadatak je klasifikacija ENF signala u smislu njihovog porijekla, uz prethodno učenje poznatih karakteristika ENF signala.

### 7.1. Klasifikacija podataka

"Klasifikacija je operacija koja smješta svaku instancu iz seta podataka koji se izučava u jednu od specifičnih, unaprijed određenih klasa, na osnovu karakteristika te instance" [14].

U praksi obično postoje dvije klase za klasifikaciju, koje se odnose na to da li nešto pripada specifičnoj klasi ili ne pripada. Na osnovu tih informacija se formira model koji se koristi za određena predviđanja.

Klasifikacija koristi skup podataka za treniranje i testiranje. U skupu podataka za treniranje, svaka instanca je opisana fiksnim brojem atributa, pri čemu je jedan od atributa klasa.

Algoritam klasifikacije na osnovu ulaznog skupa podataka za treniranje i odgovarajuće labele klase proizvodi klasifikator. Zadatak klasifikatora je da instance za koje nije poznata labela klase, odnosno koje pripadaju skupu podataka za testiranje, dodijeli određenoj klasi, onoliko tačno koliko je moguće. Na slici 7.1. je prikazana blok struktura modela za gradnju klasifikatora i njegovo testiranje.

Proces klasifikacije se obično izvršava u 4 koraka:

- 1. faza treniranja algoritam klasifikacije pravi klasifikator analizirajući ili "učeći" iz trening skupa načinjenog od instanci iz baze podataka,
- 2. faza testiranja testiranje modela koji je rezultirao iz trening seta na drugim, instancama neovisnim od trening instanci,

- 3. faza validacije mjerenje performansi odabranog modela,
- 4. primjena rezultirajući model se primjenjuje na cijeli set podataka koji se modelira.



Slika 7.1. Pojednostavljena blok struktura modela za gradnju klasifikatora

Neki od algoritama klasifikacije podataka su [14]:

- stabla odlučivanja (eng. Decision trees),
- tehnike bazirane na pravilima,
- k najbližih susjeda (eng. k Nearest Neighbors),
- neuronske mreže,
- Naive Bayes klasifikatori,
- Bayesove mreže,
- Mašine vektorske podrške (eng. Support vector machines).

U zavisnosti od broja klasa razlikuje se:

- binarna klasifikacija (eng. binary classification) postoje samo dvije klase,
- višeklasna klasifikacija (eng. *multiclass classification*) postoji više klasa u koje podatke treba razvrstati.

Ekstrahovani ENF signali i odgovarajuće statističke značajke, prikazane u poglavlju 6. predstavljaju skup podataka za treniranje klasifikatora. Navedeni ENF signali pripadaju jednoj

od 9 dostupnih mreža, a svaka mreža predstavlja jednu zasebnu klasu. Dakle, za pravilno razvrstavanje podataka potrebno je koristiti višeklasnu klasifikaciju.

Zadatak višeklasne klasifikacije se može svesti na više zadataka binarnih klasifikacija, koje je moguće efikasno riješiti koristeći binarne klasifikatore. Najuspješniji i najčešće korišteni binarni klasifikatori su mašine vektorske podrške<sup>2</sup> (eng. . *Support vector machines – SVM*).

### 7.2. Mašine vektorske podrške

Mašine vektorske podrške se koriste za klasifikaciju linearnih i nelinearnih podataka. U suštini, SVM je algoritam koji koristi nelinearno mapiranje da transformiše originalne trening podatke u veće dimenzije. Unutar novih dimenzija, SVM traži linearni optimalni odvojeni hiperprostor, odnosno granice koje odvajaju instance jedne klase od druge, korištenjem vektora podrške i margine definisane vektorima podrške [14]. Na slici 7.2. je prikazan primjer odvajanja skupa podataka sa 2 klase korištenjem SVM.



Slika 7.2. Prikaz granice razdvajanja skupa podataka sa 2 klase [17]

<sup>&</sup>lt;sup>2</sup> Biblioteka LIBSVM implementira višeklasnu klasifikaciju za mašine vektorske podrške [16].

Vrijeme treninga SVM može biti jako sporo, ali imaju prednost u odnosu na ostale metode jer su izuzetno tačne. Zbog prethodno navedenih karakteristika, za gradnju sistema koji omogućava klasifikaciju ENF signala, koristiti će se mašine vektorske podrške.

#### Princip rada SVM klasifikacije

Postoje dvije strategije treniranja:

- jedan-naspram-ostali (eng. one-vs-all OvA),
- jedan-naspram-jedan (eng. one-vs-one OvO).

Strategija treniranja "jedan-naspram-ostali" uključuje treniranje jednog binarnog klasifikatora po klasi, pri čemu se instance te klase uzimaju kao pozitivne, a sve ostale instance kao negativne. Dakle, za slučaj M klasa, sistem će trenirati ukupno M binarnih klasifikatora. Nakon što su svi klasifikatori istrenirani, slijedi faza donošenja odluke. U ovoj fazi se nepoznati podaci prezentuju klasifikatorima koji predviđaju klasu pripadnosti. Klasifikator koji je dao najbolji rezultat pouzdanosti pobjeđuje, i nepoznatim podacima se pridružuje njegova klasa.

Strategija treniranja "jedan-naspram-jedan" uključuje treniranje M(M-1)/2 binarnih klasifikatora za M klasa. Svi binarni klasifikatori se treniraju sa jednim parom klasa od mogućih M(M-1)/2 parova, čime uče razlikovati odgovarajuće dvije klase. Prilikom donošenja odluke se primjenjuje šema glasanja (eng. *voting scheme*). Nepoznati podaci se primjene na sve klasifikatore, koji zatim dodjeljuju glasove za pojedine klase. Na kraju, pobjednik je klasa sa najvećim brojem glasova, te nepoznati podaci dobivaju oznaku iste.

80 70 60 50 uzoraka 40 20 10 Ω A В С D Ε F G Н Ι Mreža

Broj uzoraka ENF signala koji čine skup podataka za treniranje je prikazan na slici 7.3.

Slika 7.3. Broj uzoraka ENF signala za pojedine mreže

Slika 7.3. pokazuje da broj dostupnih uzoraka između pojedinih mreža nije uravnotežen, što može stvarati probleme prilikom klasifikacije. Neuravnoteženi podaci mogu dovesti do pretreniranosti (eng. *overfitting*) i pristrasnosti (eng. *bias*) prilikom testiranja sistema. Ukoliko je sistem treniran na podacima gdje većina uzoraka pripada jednoj klasi, prilikom testiranja će isti imati tendenciju dodjele testnih podataka navedenoj klasi. Da bi se riješio ovaj problem koristi se varijanta SVM koja se naziva težinski SVM (eng. *weighted SVM*).

Implementacija mašina vektorske podrške koristi fiksnu vrijednost cijene *C*, koja kontroliše kaznu za klasifikator ukoliko izvrši pogrešnu klasifikaciju uzorka. Težinski SVM koristi različite vrijednosti cijena za uzorke iz različitih klasa. Što je veći broj uzoraka (podataka) jedne klase, to je vrijednost cijene manja. Ovo nadalje znači da će kazna za pogrešnu klasifikaciju uzorka iz manje klase biti veća [18].

Ako postoji M klasa, vrijednost cijene za klasu j, koja ima  $N_j$  uzoraka je:

$$C_j = w_j \cdot C_f \tag{7.1}$$

gdje je  $C_f$ - fiksna vrijednost cijene, a  $w_i$  - težinski faktor za koji vrijedi:

$$w_j = \frac{N_{min}}{N_j} \ za \ j = 1, 2, \dots, M \ i \ N_{min} = min \ N_j$$
(7.2)

U poglavlju 6. je navedeno da je potrebno koristiti nelinearni klasifikator koji će omogućiti pravilnu klasifikaciju ENF signala. Zbog toga će se prilikom implementacije težinske SVM također koristiti i nelinearna RBF (eng. *Radial Basis Function*) funkcija, koja unosi zahtjevanu nelinearnost [18].

## 8. Klasifikacija signala

S ciljem određivanja mreže u kojoj je nastao nepoznati snimak, razvijen je poseban klasifikacijski pristup prikazan na slici 8.1. Klasifikacija signala se vrši putem tri sloja.



Slika 8.1. Troslojna klasifikacija signala

Prvi sloj klasifikacije uključuje kategorizaciju signala na audio signale i signale mreže. Utvrđeno je da audio snimci imaju malu snagu i nizak SNR, za razliku od snimaka mreže koji imaju znantno veću snagu i visok SNR. Dakle, navedeni parametri predstavljaju osnovu za klasifikaciju prvog sloja.

Drugi sloj klasifikacije uključuje određivanje nominalne frekvencije signala (50 ili 60 [Hz]). Razlog tome jeste što se računarska efikasnost i preciznost klasifikatora poboljšava ako se signali izdvoje na osnovu nominalne frekvencije, prije konačne klasifikacije.

Treći sloj čine četiri nelinearna SVM klasifikatora:

- klasifikator audio signala nominalne frekvencije 50 [Hz],
- klasifikator audio signala nominalne frekvencije 60 [Hz],
- klasifikator signala mreže nominalne frekvencije 50 [Hz],
- klasifikator signala mreže nominalne frekvencije 60 [Hz].

### 8.1. Faza treniranja klasifikatora

Skup podataka za treniranje klasifikatora je razložen na četiri grupe:

- 1. snimci mreže nominalne frekvencije 50 Hz,
- 2. snimci mreže nominalne frekvencije 60 Hz,
- 3. audio snimci i snimci mreže nominalne frekvencije 50 Hz,
- 4. audio snimci i snimci mreže nominalne frekvencije 60 Hz.

Svaka grupa je korištena za treniranje jednog klasifikatora, kako je prikazano u tabeli 8.1.

Grupa	Klasifikator
Grupa 1	klasifikator signala mreže nominalne frekvencije 50 [Hz]
Grupa 2	klasifikator signala mreže nominalne frekvencije 60 [Hz]
Grupa 3	klasifikator audio signala nominalne frekvencije 50 [Hz]
Grupa 4	klasifikator audio signala nominalne frekvencije 60 [Hz]

### Tabela 8.1. Prikaz dodijeljenih grupa za treniranje klasifikatora

U prethodnom poglavlju navedeno je da će se koristiti nelinearna RBF funkcija, koja je opisana parametrima C i  $\gamma$ . Vrijednosti ovih parametara su određene korištenjem unakrsne validacije (eng. *cross validation*). Dakle, svaki klasifikator ima vlastite vrijednosti za C i  $\gamma$ . Također, u fazi treniranja je potrebno odrediti težinske faktore za svaku od klasa (mreža) prema relaciji 7.2. U tabeli 8.2 su date vrijednosti C i  $\gamma$  za pojedine grupe, kao i težinski faktori za pojedine klase.

Grupa	Cijena C	Parametar γ	Mreža/klasa	Vrijednost težinskog faktora
Grupa 1			В	8.0357
			D	7.2581
	8	0.25	E	7.7586
	-		F	10
			G	7.2581
			Н	7.5000
Grupa 2			А	10
	4	0.0625	С	8.8525
			Ι	8.5714
	4		В	8.2813
		0.0625	D	7.5714
Grupa 3			E	8.0303
•			F	10
			G	7.5714
			Н	7.7941
			A	10
Grupa 4	4	0.0625	С	8.9855
			Ι	8.7324

Tabela 8.2. Prikaz vrijednosti parametara za gradnju klasifikatora

Nakon što su svi parametri definisani, potrebno je odrediti koje statističke značajke najviše utiču na separabilnost pojedinih grupa. Dakle, različiti problemi klasifikacije zahtijevaju različite parametre.

U poglavlju 6.8 su odabrani parametri koje je potrebno koristiti za slučajeve 50 [Hz] i 60 [Hz] mreža. Međutim, utvrđeno je da odabir parametara zavisi i od vrste zapisa, odnosno da li se radi o audio zapisu ili zapisu mreže.

Na primjer, provedeni eksperimenti su pokazali da parametri AR modela predstavljaju jako dobar kriterij za separaciju audio snimaka. Međutim, ukoliko se isti koriste za separaciju snimaka mreže, tada dolazi do smanjenja performanse klasifikatora (više griješi). Zbog toga su urađeni dodatni eksperimenti i provjere, kako bi se odabrao pravilan skup parametara.

Korištenjem unakrsne validacije za svaki klasifikator procijenjena je učinkovitost različitih statističkih značajki. Odabran je skup parametara za koji je ostvaren najveći stepen tačnosti. U tabeli 8.3 su navedeni parametri korišteni za različite klasifikatore.

	50 Hz	50 Hz	60 Hz	60 Hz
Parametar	klasifikator	klasifikator	klasifikator	klasifikator
	signala mreže	audio signala	signala mreže	audio signala
Sr. vrijednost(ENF)	$\checkmark$	~	~	~
log(var(ENF))				~
log(opseg( ENF)	$\checkmark$		$\checkmark$	✓
$log(var(A_3))$				~
$log(var(D_1))$	$\checkmark$	$\checkmark$	$\checkmark$	$\checkmark$
$log(var(D_2))$	√	√	√	√
$log(var(D_3))$	$\checkmark$	$\checkmark$	✓	✓
Koeficijent <i>a</i> <sub>1</sub>		√		√
Koeficijent <i>a</i> <sub>2</sub>		$\checkmark$		$\checkmark$
$\log(var(v(n)))$		√		
Koeficijent <i>b</i> <sub>0</sub>	$\checkmark$	✓		✓
Koeficijent <i>b</i> <sub>1</sub>		$\checkmark$	√	√
Koeficijent <i>b</i> <sub>2</sub>				√
Koeficijent b <sub>3</sub>		$\checkmark$		√
Broj ekstrema		$\checkmark$		√
Odnos $A_{f1}/A_{f3}$	$\checkmark$	$\checkmark$		$\checkmark$
Vršni faktor <i>CF</i>	✓	✓	✓	✓

Tabela 8.3. Izbor statističkih značajki za pojedine klasifikatore

Na osnovu odabranih statističkih značajki i prethodno prezentovanih parametara, dobiveni su modeli klasifikatora. Svaki model je prvo testiran na skupu podataka za treniranje, kako bi se odredile tačnosti klasifikovanih mreža.

U oblasti statističke klasifikacije se za vizualizaciju performansi algoritma koristi matrica konfuzije (eng. *confusion matrix*). Matrica konfuzije govori koliko se rezultati dobiveni

Predviđena									
klasa	Mreža								
Character	А	В	С	D	Е	F	G	Н	Ι
Stvarna									
klasa									
Mreža A	97.42	-	2.58	-	-	-	-	-	-
Mreža B	-	100	-	-	-	-	-	-	-
Mreža C	3.1	-	94.6	-	-	-	-	-	2.3
Mreža D	-	-	-	92.43	-	1.51	6.06	-	-
Mreža E	-	-	-	0.8	95.96	1.62	1.62	-	-
Mreža F	-	-	-	-	2.04	96.94	1.02	-	-
Mreža G	-	-	-	3.03	0.76	-	95.45	0.76	-
Mreža H	_	_	_	_	_	_	0.78	99.22	_
Mreža I	-	-	4.47	-	-	-	-	-	95.53

klasifikacijom razlikuju od stvarnih podataka. Rezultati dobiveni klasificiranjem skupa podataka za treniranje su prikazani u tabeli 8.4, i izraženi su u procentima [%].

Tabela 8.4. Matrica konfuzije za trening skup podataka

Redovi matrice konfuzije predstavljaju stvarne mreže, dok kolone označavaju predviđene klase od strane izgrađenog modela. Vrijednosti na dijagonali matrice konfuzije predstavljaju procenat ispravno klasifikovanih podataka. U ovom slučaju svi zapisi koji pripadaju mreži B su ispravno predviđeni, odnosno tačnost klasifikacije je 100%. Najmanja tačnost je ostvarena za zapise iz mreže D, i ona iznosi 92,43%.

### 8.2. Faza testiranja klasifikatora

Faza testiranja obuhvata predviđanje klasa za podatke koji ranije nisu prezentovani modelu klasifikacije. Skup podataka za testiranje čini ukupno 50 snimaka iz različitih mreža. Za svaki snimak je poznata mreža iz koje potiče, kako bi se mogla odrediti tačnost predviđanja modela.

U tabeli 8.5 su prikazane	stvarne i predviđene mr	eže za testni skup podataka.
---------------------------	-------------------------	------------------------------

R.b.	Stvarna mreža	Predviđena mreža	R.b.	Stvarna mreža	Predviđena mreža
1.	А	А	26.	Н	Н
2.	С	С	27.	Н	Н
3.	А	А	28.	Е	Е
4.	Ι	Ι	29.	F	F
5.	А	А	30.	G	G
6.	С	С	31.	С	С

7.	Ι	Ι	32.	Н	Ι
8.	А	А	33.	А	А
9.	Ι	Ι	34.	С	С
10.	С	Ι	35.	С	С
11.	C	С	36.	А	C
12.	Н	Н	37.	Ι	C
13.	F	D	38.	Ι	Ι
14.	E	Е	39.	F	F
15.	А	В	40.	G	G
16.	D	D	41.	D	G
17.	Н	Н	42.	В	В
18.	E	E	43.	D	D
19.	В	В	44.	G	G
20.	В	В	45.	D	G
21.	G	G	46.	D	F
22.	G	G	47.	Н	В
23.	В	В	48.	E	В
24.	G	G	49.	F	Н
25.	E	E	50.	E	E

Tabela 8.5. Prikaz stvarnih i predviđenih mreža za testni skup podataka

Kako bi rezultati klasifikacije bili pregledniji i razumljiviji formirana je matrica konfuzije prikazana tabelom 8.6. Vrijednosti u tabeli su izražene u procentima [%].

Predviđena									
klasa	Mreža								
Stvarna	А	В	С	D	E	F	G	Н	Ι
klasa									
Mreža A	71.44	14.28	14.28	-	-	-	-	-	-
Mreža B	-	100	-	-	-	-	-	-	-
Mreža C	-	-	85.72	-	-	-	-	-	14.28
Mreža D	-	-	-	40	-	20	40	-	-
Mreža E	-	16.67	-	-	83.33	-	-	-	-
Mreža F	-	-	-	25	-	50	-	25	-
Mreža G	-	-	-	-	-	-	100	-	-
Mreža H	-	16.67	_	-	-	_	-	66.66	16.67
Mreža I	-	-	20	-	-	_	-	-	80

Tabela 8.6. Matrica konfuzije za testni skup podataka

Za snimke koje pripadaju mrežama B i G ostvarena je maksimalna tačnost, odnosno svi snimci su ispravno klasifikovani. Rezultati pokazuju da je samo 40%, odnosno 50% snimaka iz mreža D i F ispravno klasifikovano.

Ukoliko se uporede mreže nominalne frekvencije 60 [Hz] (mreže A, C i I), tačnost modela se kreće u opsegu od 71% do 86%. Najmanja tačnost je ostvarena za mrežu A, i ona iznosi 71.44%. Model je za određene snimke predvidio pripadnost mrežama B i C, iako one pripadaju mreži A. Također, iz rezultata klasifikacije je vidljivo da između mreža A i C postoje preklapanja, kao i između mreža C i I. Na primjer, 14.28% snimaka mreže C je dodijeljeno mreži I, a 20% snimaka mreže I je dodijeljeno mreži C. Za razliku od toga, mreže A i I uopšte nemaju preklapanja, odnosno nijedan snimak mreže I nije klasifikovan kao mreža A i obratno.

Iz prethodno navedenog, očigledno je da mreža C po svojim karakteristikama ima sličnosti sa mrežama A i I. Međutim, bez obzira što sve tri mreže imaju vrlo slične karakteristike, uočeno je da odabrani skup parametara vrlo dobro razdvaja navedene mreže.

Rezultati klasifikacije za mreže nominalne frekvencije 50 [Hz] se kreću u opsegu od 40% do 100%. U ovom slučaju model je u mogućnosti da klasifikuje podatke u duplo više klasa (mreža). Samim tim predviđanje ispravne mreže postaje dosta teže. Prilikom izbora statističkih značajki koje opisuju ENF signale pojedinih mreža, uočeno je da mreže D, F i H imaju vrlo slične karakteristike. Za razliku od njih, mreže B, E i G su relativno dobro razdvojene, pa je i tačnost klasifikacije visoka.

Mreže nominalne frekvencije 50 [Hz] imaju značajna preklapanja u odnosu na mreže nominalne frekvencije 60 [Hz], tako da se vjerovatnoća pogrešnog klasifikovanja 50 [Hz] snimaka povećava.

Pored prethodno navedenih zaključaka, tačnost modela klasifikacije bitno zavisi i od vrste snimka. Prilikom testiranja, uočeno je da klasifikatori mrežnih snimaka imaju veću tačnost u odnosu na klasifikatore audio snimaka. U tabeli 8.7 su date tačnosti pojedinih klasifikatora.

Klasifikacija audio snimaka bitno zavisi od tačnosti ekstrahovanog ENF signala. Problem audio snimaka je vrlo visok nivo šuma, odnosno dosta nizak SNR. Zbog toga je jako teško odrediti i izdvojiti frekventnu komponentu iz koje će se ekstrahovati ENF signal.

Dakle, tačnost klasifikatora audio snimaka je moguće povećati ukoliko se uvedu dodatni koraci koji uključuju filtiranje signala i otklanjanje što je moguće više šuma.

Klasifikator	Tačnost [%]
klasifikator snimaka mreže nominalne frekvencije 50 [Hz]	89.47
klasifikator snimaka mreže nominalne frekvencije 60 [Hz]	90.91
klasifikator audio snimaka nominalne frekvencije 50 [Hz]	50
klasifikator audio snimaka nominalne frekvencije 60 [Hz]	62.5

### Tabela 8.7. Prikaz tačnosti klasifikatora

Analizom dobivenih rezultata i s ciljem njihovog poboljšavanja, moguće je predložiti sljedeće:

- ✓ izvršiti predprocesiranje audio snimaka kako bi se smanjio uticaj šuma,
- ✓ izvršiti dublju analizu frekventnog sadržaja snimka s ciljem boljeg ekstrahovanja ENF signala,
- ✓ odrediti dodatne statističke značajke koje mogu uticati na konačan ishod klasifikacije,
- ✓ koristiti kombinaciju parametara u vremenskom domenu zapisa i statističke parametre koje opisuju ENF signal za proces klasifikacije.

## 9. Zaključak

Tema ovog završnog rada je bila korištenje ENF signala za vremensku i prostornu lokalizaciju multimedijalnih signala. U prvom dijelu je dat uvod u analizu i ekstrakciju ENF signala. Opisane su parametarske i neparametarske metode koje se koriste za ekstrakciju ENF signala iz audio i video zapisa. Posebna pažnja je posvećena metodama baziranim na spektrogramu, pri čemu su navedene njihove osnovne prednosti i mane. Također, prikazan je primjer ekstrakcije ENF signala iz signala poznate frekvencije, kako bi se odabrala metoda ekstrakcije korištena u daljnjoj implementaciji završnog rada.

Na osnovu izloženog, izvršena je ekstrakcija ENF signala iz audio snimaka i snimaka mreže. Zatim je urađena detaljna analiza ENF signala, pri čemu su odabrani posebni statistički parametri koji kvantitativno opisuju ENF signale i njihove promjene.

U drugom dijelu rada objašnjen je sistem mašinskog učenja, kao i metode koje se koriste za klasifikaciju podataka. Posebna pažnja je posvećena mašinama vektorske podrške, koje su korištene kao lokacijski klasifikatori. Na kraju su objašnjene i prikazane faze treniranja i testiranja klasifikatora. Također, prikazani su rezultati klasifikacije snimaka i data su odgovarajuća objašnjenja.

Ovim završnim radom pokazano je da je moguće na osnovu ekstrakcije ENF signala, i uz postojanje odgovarajućeg modela za lokacijsku klasifikaciju odrediti mjesto nastanka audio ili video zapisa. Poželjno je da model mašinskog učenja bude treniran sa što više podataka, kako bi bolje naučio karakteristike pojedinih mreža. Pored toga, jako je bitno da model klasifikacije bude višeslojan. Višeslojnost omogućava povećanje tačnosti, a time i ispravno predviđanje.

Tačnost klasifikacije je moguće povećati pravilnim odabirom statističkih značajki. Pokazano je da određeni skupovi parametara različito utiču na separabilnost pojedinih mreža. Zbog toga je od izuzetne važnosti odrediti koje će se statističke značajke koristiti za opis pojedinih mreža. Također, rezultati su pokazali da je tačnost klasifikacije manja ukoliko se model trenira sa audio snimcima, zbog postojanja velike količine šuma.

Na kraju su dati prijedlozi koji mogu uticati na konačan ishod lokacijske klasifikacije, čime bi se postigla veća tačnost i znatno bolji rezultati.

### Literatura

[1] R. Garg. *Time and location forensics for multimedia*. PhD Thesis. University of Maryland. 2003.

[2] R. Herklotz. Information Operations & Security. [Na mreži]. Dostupno: http://www.slideshare.net/afosr/7-herklotz-information-and-ops-systems.
[Pristupljeno: 26 augusta 2016].

[3] R. Garg, A. Hajj-Ahmad, M. Wu. *Geo-location estimation from Electrical Network Frequency signals*. In *ICASSP* (pp. 2862-2866). 2013.

[4] H. McGregor. World Electricity Standards. [Na mreži]. Dostupno: https://www.quantumbalancing.com/worldelectricity/electricityif.htm.
[Pristupljeno: 26 augusta 2016].

[5] H. Su, R. Garg, A. Hajj-Ahmad, M. Wu. *ENF analysis on recaptured audio recordings*. In *ICASSP* (pp. 3018-3022). 2013.

[6] T. El Gemayel. *Feasibility of using ENF fluctuations to perform forensic digital audio authentication*. PhD Thesis. University of Ottawa. 2013.

[7] A. Hajj-Ahmad, R. Garg, M. Wu. *Instantaneous frequency estimation and localization for ENF signals*. In *APSIPA ASC* (pp. 1-10). 2012.

[8] S. Mann, L. Cuccovillo, P. Aichroth, C. Dittmar. *Combining ENF Phase Discontinuity Checking and Temporal Pattern Matching for Audio Tampering Detection*. In *GI-Jahrestagung* (pp. 2917-2927). 2013.

[9] A. J. Cooper. An automated approach to the Electric Network Frequency (ENF) criterion: theory and practice. In International Journal of Speech, Language & the Law. 2009.

[10] SP Cup 2016. *Training Dataset of 9 Grids and Practice Dataset*. [Na mreži]. Dostupno: https://piazza.com/ieee\_sps/other/sp1601/resources. [Pristupljeno: 26 augusta 2016].

[11] A. Hajj-Ahmad, R. Garg, M. Wu. *ENF-based region-of-recording identification for media signals*. In *IEEE Transactions on Information Forensics and Security* (pp. 1125-1136) 2015.

[12] M. Vetterli, J. Kovačević. Wavelets and subband coding. Prentice-Hall. 1995.

[13] GaussianWaves. *LTI system models for random signals*. [Na mreži]. Dostupno: http://www.gaussianwaves.com/2014/05/lti-system-models-for-random-signals-ar-ma-and-arma-models/. [Pristupljeno: 26 augusta 2016].

[14] Dž. Đonko. Skladište podataka i analize podataka. Univerzitet u Sarajevu. 2013.

[15] T. M. Mitchell. Machine learning. McGraw Hill. 1997.

[16] C. C. Chang, C. J. Lin. *A Library for Support Vector Machines*. [Na mreži]. Dostupno: https://www.csie.ntu.edu.tw/~cjlin/libsvm/. [Pristupljeno: 26 augusta 2016].

[17] Ng. Andrew. *Non-linear SVM classification with kernels*. [Na mreži]. Dostupno: http://openclassroom.stanford.edu/MainFolder/DocumentPage.php?course=MachineLearning &doc=exercises/ex8/ex8.html. [Pristupljeno: 26 augusta 2016].

[18] T. Razzaghi. Multilevel Weighted Support Vector Machine for Classification on Healthcare Data with Missing Values. In PloS one. 2016.

## Lista slika

Slika 1.1. Uklanjanje isječka iz originalnog snimka [2]
Slika 1.2. Koraci autentifikacije audio zapisa [1]
Slika 2.1. Svjetski standardi za električnu energiju [4]
Slika 2.2. a) ENF signal audio zapisa, b) ENF signal mreže [5]
Slika 3.1. Koncept STFT primjenom kliznog prozora na signal [6]
Slika 3.2. Poređenje vremenske i frekventne rezolucije: a) bolja vremenska rezolucija, b) bolja frekventna rezolucija) [6]
Slika 3.3. Grafički prikaz kvadratne interpolacije11
Slika 4.1. a) prikaz originalnog i zašumljenog signala, b) promjene frekvencije
Slika 4.2. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 16 [s] 16
Slika 4.3. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 32 [s] 17
Slika 4.4. Prikaz estimiranih vrijednosti frekvencije i greške estimacije za trajanje od 64 [s] 17
Slika 4.5. Estimacije ENF signala iz zašumljenog signala za a) trajanje=16 [s], b) trajanje=32 [s], c) trajanje=64 [s]
Slika 5.1. Ukupan broj zapisa skupa za treniranje klasifikatora za svaku od mreža
Slika 5.2. Princip rada algoritma za ekstrakciju ENF signala
Slika 5.3. Spektrogram i frekventni spektar snimka mreže (a i b), spektrogram i frekventni spektar audio snimka (c i d)
Slika 5.4. Izgled ENF signala za mreže nominalne frekvencije 50 [Hz]
Slika 5.5. Izgled ENF signala za mreže nominalne frekvencije 60 [Hz]
Slika 6.1. Struktura dekompozicije signala na 3 nivoa (L=3)
Slika 6.2. Separacija mreža nominalne frekvencije 50 [Hz] korištenjem različitih parametara ARMA modela
Slika 6.3. Separacija mreža nominalne frekvencije 50 [Hz] korištenjem dodatnih parametara
Slika 6.4. Prikaz cjelokupnog normalizovanog skupa podataka za treniranje
Slika 6.5. Normalizirane vrijednosti statističkih značajki za 60 [Hz] mreže (a) i 50 [Hz] mreže (b i c)
Slika 6.6. Prikaz separabilnosti mreža B i H u odnosu na preostale mreže
Slika 6.7. Separabilnost 50 [Hz] mreža korištenjem a) koeficijenata $D_1$ , $D_2$ i vršnog faktora, b) koeficijenta $b_0$ , odnosa $f_1/f_3$ i vršnog faktora
Slika 6.8. Separabilnost 60 [Hz] mreža korištenjem a) koeficijenta $D_1$ , odnosa $f_1/f_3$ i broja ekstrema, b) koeficijenata $D_1$ , $b_2$ i broja ekstrema, c) koeficijenata $D_1$ , $a_2$ i vršnog faktora 39
Slika 7.1. Pojednostavljena blok struktura modela za gradnju klasifikatora

Slika 7.2. Prikaz granice razdvajanja skupa podataka sa 2 klase [17]	. 42
Slika 7.3. Broj uzoraka ENF signala za pojedine mreže	. 43
Slika 8.1. Troslojna klasifikacija signala	. 45

# Lista tabela

Tabela 4.1. Poređenje metoda spektrograma korištenjem karakterističnih vrijednosti	. 18
Tabela 5.1. Nominalne frekvencije mreža	. 21
Tabela 6.1. Predložene statističke značajke ENF signala	. 32
Tabela 8.1. Prikaz dodijeljenih grupa za treniranje klasifikatora	. 46
Tabela 8.2. Prikaz vrijednosti parametara za gradnju klasifikatora	. 47
Tabela 8.3. Izbor statističkih značajki za pojedine klasifikatore	. 48
Tabela 8.4. Matrica konfuzije za trening skup podataka	. 49
Tabela 8.5. Prikaz stvarnih i predviđenih mreža za testni skup podataka	. 50
Tabela 8.6. Matrica konfuzije za testni skup podataka	. 50
Tabela 8.7. Prikaz tačnosti klasifikatora	. 52

## **Prilog A**

### Metoda maksimalne energije sa kvadratnom interpolacijom

```
function [frekvencije, vrijeme] = FrekvMEWQI(x, Fs, harmonik)
% x - audio signal iz kog se izvlaci ENF
% Fs - frekvencija sempliranja
frekvencije=[];
vrijeme=[];
%% Parametri FFT-a
N=32*1024; %Broj tacaka FFT (1024 priblizno 1s)
f = Fs/2*linspace(0,1,N/2+1);
L=N;
disp('Rezolucija');
disp(1000/N);
%% Izdvajanje opsega frekvencija od interesa zbog poboljsanja estimacije
f0=harmonik;
deltaf=1; %opseg [f0-deltaf, f0+deltaf]
indeksi=[]; %vektor za smjestanje indeksa
for i=1:length(f)
    if (f(i) \leq f0 + deltaf) \&\& (f(i) \geq f0 - deltaf)
    indeksi=[indeksi i];
    end
end
%% Implementacija metode
for i=1:N/2:length(x)-N
    signal=x(i:i+N-1); %Dio signala u vremenu
    Y = fft(signal,N)/L; %Racunanje FFT-a
    % Ukidanje uzoraka van zeljenog opsega frekvencija
    Ynovo=zeros(size(Y));
    Ynovo(indeksi)=Y(indeksi); %dodavanje izdvojenog spektra
    % Odredjivanje indeksa frekvencije na kojoj je max. spectral power
    %%component
    [C, kmax]=max(2*abs(Ynovo(1:N/2+1))); %kmax je taj indeks
    %Odredjivanje parametra p (prema izrazu 3.4.)
    k1=kmax-1; %uzorak prije
    k2=kmax+1; %uzorak poslije
    y1=20*log10(abs(Y(k1)));
    y2=20*log10(abs(Y(k2)));
    ymax=20*log10(abs(Y(kmax)));
    p=0.5*(y1-y2)./(y1-2*ymax+y2); % izraz 3.3
    kt=kmax+p; %indeks koji pokazuje na pravu vrijednost frekvencije
    ft=(kt-1)*Fs/N; %estimirana frekvencija
    frekvencije=[frekvencije ft];
end
vrijeme=(0:length(frekvencije)-1)*0.001*N/2;
end
```

## **Prilog B**

### Metoda otežane energije

```
function [ frekvencije, vrijeme ] = FrekvWEM( x, Fs, harmonik )
% x - audio signal iz kog se izvlaci ENF
% Fs - frekvencija sempliranja
frekvencije=[];
vrijeme=[];
%% Parametri FFT-a
N=32*1024; %Broj tacaka FFT (1024 priblizno 1s)
f = Fs/2*linspace(0,1,N/2+1);
L=N;
disp('Rezolucija');
disp(1000/N);
%% Izdvajanje opsega frekvencija od interesa zbog poboljsanja estimacije
f0=harmonik;
deltaf=1; %opseg [f0-deltaf, f0+deltaf]
indeksi=[]; %vektor za smjestanje indeksa
for i=1:length(f)
    if (f(i) \leq f0 + deltaf) \&\& (f(i) \geq f0 - deltaf)
    indeksi=[indeksi i];
    end
end
%% Implementacija metode
for i=1:N/2:length(x)-N
    signal=x(i:i+N-1); %Dio signala u vremenu
    Y = fft(signal,N)/L; %Racunanje FFT-a
    % Ukidanje uzoraka van zeljenog opsega frekvencija
    Ynovo=zeros(size(Y));
    Ynovo(indeksi)=Y(indeksi); %dodavanje izdvojenog spektra
    %%Odredjivanje indeksa frekvencije
    [C, kmax]=max(2*abs(Ynovo(1:N/2+1))); %kmax je taj indeks
    fmax=f(kmax); % Noseca frekvencija trenutnog okvira
    %odredjivanje granica L1 i L2 (izraz 3.8.)
    deltaF=0.5; % Dozvoljeno odstupanje frekvencije
    L1=(fmax-deltaF) *N/Fs;
    L2=(fmax+deltaF)*N/Fs;
    %L1 i L2 trebaju biti cijeli brojevi, slijedi zaokruzivanje
    L1=floor(L1); %zaokruzivanje na donji nivo
    L2=ceil(L2); %zaokruzivanje na gornji nivo
    brojnik=0;
    nazivnik=0;
    %Implementacija izraza 3.7.
    for j=L1:L2
        brojnik=brojnik+f(j)*abs(Y(j)).^2;
        nazivnik=nazivnik+abs(Y(j)).^2;
    end
    F=brojnik./nazivnik; %estimirana frekvencija
    frekvencije=[frekvencije F]; %vektor estimata
 end
vrijeme=(0:length(frekvencije)-1)*0.001*N/2;
end
```

## **Prilog C**

### Funkcija za učitavanje i određivanje snage signala

```
function [ frekvencije, vrijeme ] = Ekstrakcija ENF Signala( x, Fs )
% Funkcija za ekstrakciju ENF signala iz audio i power snimaka
% 1. korak - racunanje frekventnog spektra signala
% 2. korak - odredjivanje snage signala za klasifikaciju - da li je u
% pitanju audio signal ili power signal
% 3. korak - odredjivanje harmonika iz kog se ekstrahuje ENF signal
% 4. korak - ekstrakcija ENF signala koristeci Weighted Energy metodu
% 5. korak - crtanje ENF signala
%% Parametri FFT-a
L = 32 \times 1024;
N=L;
data=x;
% FFT signala
y = fft(data, N)/L;
f = Fs/2 * linspace(0,1,N/2+1);
%% Odredjivanje snage signala (mala snaga->audio signal, velika snaga-
>power signal
power = (norm(x)^2)/length(x);
if (power<0.01) % Empirijski je odredjena ova granica
    % Odredjivanje nominalne frekvencije audio signala
    nominalna frekvencija= NominalnaFrekvencijaAudioSignala(x, Fs);
else
    % Odredjivanje nominalne frekvencije power signala
    nominalna frekvencija= NominalnaFrekvencijaPowerSignala(x, Fs);
end
%% Odredjivanje amplitude na osnovnom i visim harmonicima
amplitude=[];
indeksi=[];
broj harmonika=4; % definisanje broja harmonika
for i=1:broj harmonika
    pom=find(f<=i*nominalna frekvencija); % indeks koji priblizno odgovara</pre>
i*nominalna frekvencija
    pom=pom(end);
    indeksi=[indeksi pom];
    vrijednost=abs(y(pom, 1)); % Vrijednost spektra na frekvenciji
i*nominalna frekvencija
    amplitude=[amplitude vrijednost]; %Vektor amplituda
end
% Odredjivanje maksimalne amplitude za ekstrakciju ENF signala
maksimalna amplituda=max(amplitude);
frekvencija harmonika=f(indeksi(find(maksimalna amplituda==amplitude)));
harmonik=find(maksimalna amplituda==amplitude);
%% Ekstrakcija ENF signala
[ frekvencije, vrijeme ] = FrekvWEM( x, Fs, nominalna frekvencija*harmonik
);
% Vracanje frekvencije ENF signala u osnovni opseg
frekvencije=frekvencije./harmonik;
```

end

## **Prilog D**

### Funkcija za određivanje nominalne frekvencije audio snimka

```
function [ nominalna frekvencija ] = NominalnaFrekvencijaAudioSignala( x,
Fs )
% Funkcija za odredjivanje nominalne frekvencije audio signala
%% Definisanje FFT parametara
L = 32 \times 1024;
N=L; % Broj tacaka FFT-a
data=x;
y = fft(data,N)/L; % FFT signala
f = Fs/2 * linspace(0,1,N/2+1); % vektor frekvencija
%% Odredjivanje nominalne frekvencije
f1=50; % 50 Hz
f2=60; % 60 Hz
d1=0.1; % f+/-d1 - opseg unutar kog se odredjuje max. amplituda spektra
d2=1.5; % f+/-(d1+d2)opseg unutar kog se odredjuje mean amplituda spektra
amplituda 50=[];
amplituda 60=[];
broj harmonika=4; %uzimamo 4 harmonika
for i=1:broj harmonika
    %% Odredjivanje parametara za i*50 Hz
    % Odredjivanje indeksa opsega za trazenje max. amplitude
    [a d1, b d1]=find(f>=i*f1-d1 & f<=i*f1+d1);</pre>
    opseg=f(1, b d1); % Dobiveni opseg frekvencija
    vrijednosti= abs(y(b d1, 1)); %Vrijednosti spektra na tim frekvencijama
    maksimum=max(vrijednosti); % Maksimalna vrijednost
    indeks=find(abs(y(1:N/2+1))==maksimum); % Indeks maksimalne vrijednosti
    f osnovnol=f(indeks); % Frekvencija na kojoj je maksimalna vrijednost
    % Odredjivanje indeksa opsega za trazenje mean-a vrijednosti opsega
    [a mean1, b mean1]=find(f>=i*f1-d1-d2 & f<=i*f1-d1); % Opseg [i*50-d1-
d2, i*50-d1]
    mean1=abs(y(b mean1, 1)); % Vrijednosti spektra u tom opsegu
    [a mean1, b mean1]=find(f>=i*f1+d1 & f<=i*f1+d1+d2); % Opseg [i*50+d1,
i*50+d1+d2]
    mean2=abs(y(b mean1, 1));
    % Odredjivanje srednje vrijednosti na datim opsezima
    mean1=mean(mean1);
    mean2=mean(mean2);
    uk mean=(mean1+mean2)/2; % Ukupna sr. vrijednosti je aritmeticka
sredina
    % Odredjivanje stvarne vrijednosti amplitude za frekvenciju i*50 Hz
    h1=maksimum-uk mean;
    amplituda 50=[amplituda 50 h1];
    %% Odredjivanje parametara za i*60 Hz
    % Odredjivanje indeksa opsega za trazenje max. amplitude
    [a d2, b d2]=find(f>=i*f2-d1 & f<=i*f2+d1);
    opseg=f(1, b d2); % Dobiveni opseg frekvencija
```

```
vrijednosti= abs(y(b d2, 1)); %Vrijednosti spektra na tim frekvencijama
    maksimum=max(vrijednosti); % Maksimalna vrijednost
    indeks=find(abs(y(1:N/2+1))==maksimum); % Indeks maksimalne vrijednosti
    f osnovnol=f(indeks); % Frekvencija na kojoj je maksimalna vrijednost
    % Odredjivanje indeksa opsega za trazenje mean-a vrijednosti opsega
    [a mean2, b mean2]=find(f>=i*f2-d1-d2 & f<=i*f2-d1); % Opseg [i*60-d1-
d2, i*60-d1]
    mean1=abs(y(b mean2, 1)); % Vrijednosti spektra u tom opsequ
    [a mean2, b mean2]=find(f>=i*f2+d1 & f<=i*f2+d1+d2); % Opseq [i*60+d1,
i*60+d1+d2]
    mean2=abs(y(b mean2, 1));
    % Odredjivanje srednje vrijednosti na datim opsezima
    mean1=mean(mean1);
    mean2=mean(mean2);
    uk mean=(mean1+mean2)/2; % Ukupna sr. vrijednosti je aritmeticka
sredina
    % Odredjivanje stvarne vrijednosti amplitude za frekvenciju i*60 Hz
    h2=maksimum-uk mean;
    amplituda 60=[amplituda 60 h2];
end
%% Odredjivanje nominalne frekvencije signala
% Racunanje srednje vrijednosti po svim harmonicima
% amplituda_50=mean(amplituda_50);
% amplituda_60=mean(amplituda_60);
amplituda 50=abs(mean(amplituda 50));
amplituda 60=abs(mean(amplituda 60));
if(amplituda 50>amplituda 60)
    nominalna frekvencija=f1; % f1=50 Hz
else
    nominalna frekvencija=f2; % f2=60 Hz
end
end
```

## **Prilog E**

### Funkcija za određivanje nominalne frekvencije snimka mreže

```
function [ nominalna_frekvencija ] = NominalnaFrekvencijaPowerSignala( x,
Fs )
% Funkcija za odredjivanje nominalne frekvencije signala mreže
%% Parametri FFT-a
L = 32*1024;
N=L;
data=x;
% FFT signala
y = fft(data,N)/L;
f = Fs/2 * linspace(0,1,N/2+1);
%% Maksimum spektra
maksimum= max(abs(y(1:N/2+1)));
indeks=find(maksimum<=abs(y(1:N/2+1)));
frekvencija max=f(indeks);
```

```
%% Nominalna frekvencija
broj harmonika=4;
f1=50;
f2=60;
for i=1:broj_harmonika
    % Ako se frekvencija max. spektra nalazi u opsegu +/- 1 [Hz], odredi se
    % tacna nominalna frekvencija
    a=i*f1-frekvencija max;
    b=i*f2-frekvencija max;
    if(abs(a) < 2 || abs(b) < 2)
        if(abs(a) < abs(b))
            nominalna frekvencija=50;
        else
            nominalna frekvencija=60;
        end
    end
end
end
```

## Prilog F

### Funkcije za izdvajanje statističkih značajki signala

```
function [mat features] = Feature Extraction db4(frekvencije)
%% Funkcija za ekstrakciju osobina (features extraction) ENF signala
%% Srednja vrijednost (mean), varijansa i opseg (range)
sr vrijednost=mean(frekvencije);
varijansa=log10(var(frekvencije));
maksimum=max(frekvencije);
minimum=min(frekvencije);
range=log10 (maksimum-minimum);
%% Wavelet transformacija sa 3 nivoa L=3, koristeci 'sym4'
s=frekvencije;
[C,L] = wavedec(s,3,'sym4');
cA3 = appcoef(C, L, 'sym4', 3);
[cD1, cD2, cD3] = detcoef(C, L, [1, 2, 3]);
A3 = wrcoef('a',C,L,'sym4',3);
D1 = wrcoef('d',C,L,'sym4',1);
D2 = wrcoef('d',C,L,'sym4',2);
D3 = wrcoef('d',C,L,'sym4',3);
% Odredjivanje varijanse aproksimacije i detalja
var A3=log10(var(A3));
var D1=log10(var(D1));
var D2=log10(var(D2));
var D3=log10(var(D3));
%% AR model 2 reda - Yule-Walker metoda
[a,e] = aryule(frekvencije,2);
% Parametri AR modela
al=a(2); % Koeficijent al - normalizovan
a2=a(3); % Koeficijent a2 - normalizovan
e=log10(e); % log varijanse bijelog šuma
%% Formiranje matrice osobina signala
mat features=[sr vrijednost varijansa range var A3 var D1 var D2 var D3 a1
a2 e];
end
```

```
function [ time features ] = Features Extraction Time Domain(signal,
nominalna frekvencija)
% Funkcija za ekstrakciju osobina vremenskog signala
Fs=1000;
%% Crest factor
CF=peak2rms(signal);
%% Odnos harmonika f1/f3 signala
L = 32 \times 1024;
N=L;
data=signal;
% FFT signala
y = fft(data,N)/L;
f = Fs/2 * linspace(0,1,N/2+1);
%% Odredjivanje amplitude na osnovnom i visim harmonicima
amplitude=[];
indeksi=[];
broj harmonika=4; % definisanje broja harmonika
for i=1:broj harmonika
    pom=find(f<=i*nominalna frekvencija); % indeks koji priblizno odgovara</pre>
i*nominalna frekvencija
    pom=pom(end);
    indeksi=[indeksi pom];
    vrijednost=abs(y(pom, 1)); % Vrijednost spektra na frekvenciji
i*nominalna frekvencija
    amplitude=[amplitude vrijednost]; %Vektor amplituda
end
f1=amplitude(1); %amplituda prvog harmonika
f3=amplitude(3); %amplituda treceg harmonika
ratio=f1/f3;
time features=[ratio CF];
end
```

## Prilog G

### Funkcija za normalizaciju podataka

```
function [ norm matrica osobina ] = z_score_normalizacija( matrica_osobina
)
%% Normalizacija matrice osobina - koristeci z - score normalizaciju
broj osobina=size(matrica osobina, 2); % Broj kolona matrice osobina =
broju osobina
norm matrica osobina=zeros(size(matrica osobina)); % Normalizirana matrica
osobina
for i=1: broj_osobina-1 % ne uzima se posljednja kolona koja predstavlja
klasu mreze
    % Srednja vrijednost (mean) od i-te kolone
    norm mean=mean(matrica osobina(:, i));
    % Varijansa (variance) od i-te kolone
    norm var=var(matrica osobina(:, i));
    % Standardna devijacija od i-te kolone
    norm std=sqrt(norm var);
    % Normalizirana i-ta kolona
    norm matrica osobina(:, i)=(matrica osobina(:, i)-norm mean)./norm std;
end
norm matrica osobina(:, broj osobina)=matrica osobina(:, broj osobina); %
Posljednja kolona predstavlja klasu mreze
```

end