

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET

Sanja M. Vuđnović

DETKECIJA STANJA ROTACIONIH
AKTUATORA ZASNOVANA NA ANALIZI
AKUSTIČKIH SIGNALA

doktorska disertacija

Beograd, 2017.

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Sanja M. Vujičić

STATE DETECTION OF ROTATING
ACTUATORS BASED ON ACOUSTIC SIGNAL
ANALYSIS

Doctoral Dissertation

Belgrade, 2017.

Mentor:

dr ŽELJKO ĐUROVIĆ, redovni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

Članovi komisije:

dr BRANKO KOVAČEVIĆ, redovni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

dr ZORAN PERIĆ, redovni profesor
Univerzitet u Nišu – Elektronski fakultet

dr GORAN KVAŠČEV, docent
Univerzitet u Beogradu – Elektrotehnički fakultet

dr MILAN BEBIĆ, docent
Univerzitet u Beogradu – Elektrotehnički fakultet

dr DRAGANA ŠUMARAC PAVLOVIĆ, vanredni profesor
Univerzitet u Beogradu – Elektrotehnički fakultet

Datum odbrane: _____

Zahvalnica

Pre svega, želela bih da se zahvalim mentoru, prof. dr Željku Đuroviću, na ukazanom poverenju i pruženoj podršci. Ogromno strpljenje, iskustvo i znanje koje je uložio u proces vođenja ove disertacije bilo je dragoceno, a njegovim srdačnim i otvorenim odnosom prema studentima i kolegama mi je pokazao kako jedan inženjer, naučnik i predavač treba da se ponaša. Veliku zahvalnost dugujem i Branku Kovačeviću, Zoranu Periću, Goranu Kvaščevu, Milanu Bebiću i Dragani Šumarac Pavlović na konstruktivnim komentarima i diskusijama za vreme i nakon pisanja teze. Bez njihove ažurnosti i posvećenosti ova disertacija bi imala znatno drugačiji oblik.

Proces izrade doktorske disertacije je u velikoj meri olakšan konstantnim ohrabrenjem i razumevanjem koje mi je pružila porodica. Mama Dragica, tata Miroslav, Marjan, Marko i Nataša bili su moj oslonac tokom celog procesa školovanja i stvaranja ove teze. Bez njihove bezrezervne podrške teško da bih mogla da se izborim sa svim izazovima i spoticanjima na koje sam naišla. Hvala Vam!

Najzad, veliku zahvalnost dugujem kolegama sa Katedre. Aleksandra Marjanović je stalno bila prva na udaru svih mojih problema i dilema, i junački je uskakala u pomoć svaki put kad mi je to bilo potrebno. Ona je velikim delom zaslужna za relaksiranje mojih obaveza kako bih mogla da se posvetim tezi. Predrag Tadić i Kosta Jovanović su uvek bili tu za pomoć, ručak ili međusobno jadanje, a druženje sa njima mi je ulepšalo dane provedene na fakultetu. Aleksandar Rakić mi je pričama o stručnim (i ne toliko stručnim) temama često pomagao u korekciji prioriteta onda kada se zanesem raznim obavezama. Tomislav Šekara i Stevica Graovac su me nesebično uveli u način života na fakultetu kada sam se tek zaposlila. Njihovi saveti i zanimljive priče i anegdote su učinile da se osećam prihvaćeno i zaštićeno. Veliko hvala i Veljku Papiću zbog lepe saradnje na mnogim predmetima i projektima, kao i Peđi Todorovu za društvo i pomoć u laboratorijama i termoelektranama prilikom snimanja eksperimenta.

Naslov teze: Detekcija stanja rotacionih aktuatora zasnovana na analizi akustičkih signala

Rezime: Danas se u industriji sve veći akcenat stavlja na razvijanje ekonomičnijih načina održavanja mašina i blagovremene detekcije otkaza. Ovo nije toliko iznenađujuće ako se uzme u obzir procena da je čak jedna trećina troškova održavanja prosečnog industrijskog postrojenja posledica suvišnog ili neefikasnog održavanja. Moderne tehnike prediktivnog održavanja su se razvile upravo sa ciljem produženja životnog veka mašina, blagovremene detekcije istrošenosti komponenti i, samim tim, uštede finansijskih resursa. Ove metode se zasnivaju na akviziciji odgovarajućih signala (merenje vibracije, termografskih snimaka i sl.), njihovoj obradi i analizi i, na kraju, donošenju odluke o stanju mašine i proceni neophodnosti remonta.

Rotacione mašine su posebno zastupljene u industriji i veoma prisutne u modernoj literaturi koja se bavi prediktivnim održavanjem, a za njihovu dijagnostiku kao najinformativniji su se pokazali signali vibracije. Korišćenje signala vibracije za izdvajanje obeležja i kasniju dijagnostiku stanja uređaja je dobro utemeljeno u literaturi i testirano je na različitim tipovima mašina uključujući i industrijske mlinove. Međutim, u zadnjih deset godina se sve veći akcenat stavlja na korišćenje akustičkih signala za detekciju otkaza. Pokazano je da mogu da budu podjednako informativni kao signali vibracije, a da zbog njihove velike osetljivosti na promene u okruženju mogu ranije da detektuju određene otkaze. Takođe, senzori za detekciju zvuka su jeftiniji, bezkontaktni i mogu snimati signale u neposrednom okruženju mašine dok je ona u funkciji.

Mnogo uspeha je postignuto korišćenjem akustičkih senzora za prediktivno održavanje; međutim, gotovo svi ovi uspesi su zabeleženi u striktno kontrolisanim laboratorijskim uslovima. Naime, veliki problem kod korišćenja zvučnih signala u industrijskim okružnjima je u tome što su izuzetno podložni okolnom šumu koji je uvek prisutan u realnim uslovima. Filtriranje tog šuma tradicionalnim tehnikama često nije moguće bez gubitaka korisnih informacija, pa svi benefiti korišćenja zvuka za detekciju otkaza često bivaju zasenjeni ovim jednim nedostatkom.

Cilj istraživanja u okviru doktorske disertacije jeste realizacija nove metodologije koja na osnovu akustičkih signala u kontaminiranoj sredini traži informativna obeležja u vremenskom i frekvencijskom području, pri čemu se posebna pažnja posvećuje predobradi signala u cilju detekcije postojanja kontaminirajuće komponente. Istraživanje će se koncentrisati na probleme u termoenergetskim postrojenjima (detekcija stanja radnih kola mlinova), ali verujemo da se rezultati mogu generalizovati i proširiti na šиру familiju rotacionih aktuatora kao što su napojne pumpe, kompresori, ventilatori i sl.

Jedan deo istraživanja je orijentisan na razvijanje novih algoritama za samu detekciju

stanja udarnih ploča korišćenjem akustičkih signala, upotrebom tehnika baziranim na podacima (engl. *data driven*). Ovo je realizovano obradom snimljenih signala i izdvajanjem relevantnih obeležja zvuka u vremenskom i frekvencijskom području. Dobijena obeležja se zatim analiziraju nekim od algoritama prepoznavanja oblika (klasifikacija na bazi redukcije dimenzija ili supstraktivna klasterizacija) sa ciljem razvijanja metrike koja govori o nivou istrošenosti radnih kola unutar mlinova. Ta metrika može da bude funkcija euklidskog rastojanja u višedimenzionom prostoru ili statističkog rastojanja u dvodimenzionalnom prostoru. Drugi deo istraživanja bazira se na predobradi zvučnog signala u cilju detekcije kontaminacije. Ovaj korak je izuzetno važan s obzirom da je ustanovljeno da su postojeće metode za detekciju stanja sklane do nošenju pogrešnih zaključaka kada se koriste zašumljena merenja. Za detekciju kontaminacije obavlja se analiza buke rotacionih aktuatora posmatranjem promene statističkih karakteristika signala u vremenu. Ova promena može najočiglednije da se detektuje upotrebom statističkih alata kao što je QQ kriva.

Osim doprinosa u vidu estimacije stanja radnih kola mlinova i adaptivne detekcije kontaminacije zvučnog signala, konačni cilj je razvijanje novih metoda koje je moguće generalizovati za primenu na širokom spektru rotacionih aktuatora, kao i otvaranje prostora za korišćenje akustičkih senzora za potrebe održavanja i detekcije otkaza u industrijskim postrojenjima. Dodatno, implementacijom ovih algoritama na jednostavnom mikrokontrolerskom uređaju omogućilo bi se uvođenje prediktivnog održavanja za razne industrijske elemente uz minimalne izmene u načinu funkcionisanja industrijskih postrojenja. Time bi se, uz minimalna ulaganja, uštedelo na troškovima održavanja i produžio bi se životni vek rotacionih elemenata. Signali korišćeni za razvoj i testiranje algoritama u okviru ove disertacije dobijeni su eksperimentalnim snimanjima zvuka ventilatorskih mlinova u termoelektrani Kostolac A1.

Ključne reči: akustički signali, rotacioni aktuatori, detekcija stanja, termoelektrane, prediktivno održavanje, robusna predobrada, klasifikacija, prepoznavanje oblika

Naučna oblast: Elektrotehnika i računarstvo

Uža naučna oblast: Upravljanje sistemima i obrada signala

UDK broj: 621.3

Dissertation title: State detection of rotating actuators based on acoustic signal analysis

Abstract: In recent years in modern industry great emphasis has been placed on the development of cost-effective approaches to machine maintenance and timely fault detection. This is not so surprising if one takes into account the estimate that one third of the maintenance costs of an average industrial plant are due to excessive or inefficient upkeep. Modern predictive maintenance techniques were developed with goal to prolong life expectancy of machines and detect worn components in timely manner, thus significantly reducing maintenance costs. These methods are based on acquisition of appropriate signals (vibration measurements, thermographic images, etc.), processing and analysis of those signals and, finally, estimating the state of the machine and assessing the necessity of repairs.

Rotating machines are especially common in industry and are frequently mentioned in modern predictive maintenance literature, with vibration signals being the most informative resource for their diagnostics. The usage of vibration signals for feature extraction and machine condition diagnostics is well founded in the literature and tested on various types of actuators, including industrial mills. However, in the last decade an increased emphasis has been placed on usage of acoustic signals with purpose of fault detection. It has been shown that they can be as informative as vibration signals and can enable the detection of certain changes even faster, due to their high sensitivity to certain changes in the environment. Also, acoustic sensors are cheaper, contactless and can record signals in an immediate vicinity of an actuator while it is in operation.

There has been much success in using acoustic sensors for predictive maintenance; however, almost all those results are obtained in strictly controlled laboratory conditions. A major issue in using these signals in industrial surroundings is their high susceptibility to the surrounding noise which is always present in real-life conditions. Filtering the noise using traditional techniques is usually not possible without significant loss of useful information, so all the benefits of using sound signals for fault detection are often overshadowed by this one flaw.

The main objective of the research conducted within this doctoral dissertation is the development of new methodology which, using acoustic signals in contaminated environment, searches for informative features in time and frequency domain. The special attention will be given to preprocessing of the signal for the purpose of detecting the existence of contaminating components. The research will be focused on problems in thermal power plants (state detection of impellers within mills), but it is our belief that the results can be generalized and expanded to broad family of rotating actuators like

feedwater pumps, compressors, ventilators, etc.

One part of this research is oriented towards the development of new algorithms for state detection of impact plates using acoustic signals by applying data-driven techniques. This can be conducted by processing the recorded signal and extracting the relevant features in time and frequency domain. The features are then analyzed using pattern recognition algorithms (classification using dimension reduction or subtractive clustering). The final goal is the development of metric which can indicate the level of impact plate wear. The metric can be a function of Euclidean distance in multi-dimensional space, or statistical distance in two-dimensional region. The second part of the research is based on sound signal preprocessing for the purpose of contamination detection. This is an extremely important step due to the fact that the current state detection methods are prone to making wrong decisions when working with noisy measurements. For the purpose of contamination detection, a change of statistical parameters of the signal is observed. This change can be most easily detected using statistical tools such as QQ plot.

Apart from contributions such as state estimation of impact plates of the mill and adaptive contamination detection of acoustic signal, the final goal is the development of new methods which can be easily generalized so to become applicable to wide specter of rotating actuators, as well as enabling the usage of acoustic sensors for the purpose of fault detection in industrial plants. Additionally, by implementing these algorithms on a simple microcontroller, introduction of predictive maintenance techniques for various industrial components can be introduced with minimal changes in the way industrial plants function. In this way there would be a significant reduction to the costs of maintenance, and the life expectancy of rotating elements would be prolonged, using financial investments. Signals used for development and testing of the algorithms within this dissertation are obtained using experimental recordings of sound of ventilation mills in thermal power plant Kostolac A1.

Keywords: acoustic signals, rotating actuators, state detection, thermal power plants, predictive maintenance, robust preprocessing, classification, pattern recognition

Research area: Electrical and Computer Engineering

Research sub-area: System control and signal processing

UDC number: 621.3

Sadržaj

1 Uvod	1
1.1 Tehnike održavanja postrojenja	2
1.2 Estimacija stanja rotacionih aktuatora	4
1.3 Vibraciona i zvučna dijagnostika	5
1.4 Motivacija i doprinos	7
1.5 Struktura teze	9
2 Akustički signali u prediktivnom održavanju	11
2.1 Osobine zvuka	12
2.1.1 Jednostavno harmonijsko kretanje	12
2.1.2 Prostiranje zvuka	14
2.1.3 Zvučni pritisak	16
2.1.4 Frekvencijski opseg zvuka	17
2.2 Obrada i analiza zvučnog signala	19
2.2.1 Vremenski domen	20
2.2.2 Frekvencijski domen	23
2.2.3 Vremensko-frekvencijski prikaz	28
2.3 Karakterizacija zvučnog signala u industriji	39
2.4 Studija slučaja: ventilatorski mlin u TEKO A1	42
2.4.1 Ventilatorski mlinovi	42
2.4.2 Akvizicija zvučnog signala	45
3 Detekcija kontaminacije akustičkog signala	48
3.1 QQ krive	50
3.2 Algoritam za adaptivnu detekciju kontaminacije	53

3.3	Klasifikacija kontaminacije	62
3.3.1	Algoritam baziran na Neyman-Pearson testu	62
3.3.2	Algoritam baziran na metodi nosećih vektora	66
3.4	Kratak rezime	76
4	Detekcija stanja rotacionih aktuatora	77
4.1	Izdvajanje obeležja i analiza diskriminante	79
4.1.1	Akvizicija signala	79
4.1.2	Izdvajanje obeležja	79
4.1.3	Analiza diskriminante	81
4.2	Binarna procena stanja metodom Bajesovih mreža	84
4.3	Kontinualna estimacija stanja	91
4.3.1	Metoda procene statističke distance	91
4.3.2	Metoda suptraktivne klasterizacije	96
4.4	Kratak rezime	100
5	Zaključak	101
	Literatura	105

Lista slika

2.1	Jednostavno harmonijsko kretanje čestice.	12
2.2	Harmonici na učestanostima ω_0 , $2\omega_0$ i $3\omega_0$ (gore) i suma sva tri harmonika (dole).	13
2.3	Poređenje harmonika i oktave za osnovnu frekvenciju 100 Hz	14
2.4	Prikaz prostiranja zvučnog talasa kroz vazduh	15
2.5	Opseg frekvencija i pritiska zvuka koji je potreban da bi ga detektovalo ljudsko uvo	18
2.6	Šematski prikaz procesa obrade signala	19
2.7	Anvelopa (gore) i trenutna frekvencija (dole) stacionarnog signala.	22
2.8	Anvelopa (gore) i trenutna frekvencija (dole) nestacionarnog signala.	23
2.9	Amplitudski spektar signala iz primera 1.	25
2.10	Amplitudski spektar signala iz primera 2.	26
2.11	Blok dijagram za izračunavanje Mel-kestralnih koeficijenata.	28
2.12	Nestacionaran signal u vremenskom (crveno) i frekvencijskom domenu (crno).	29
2.13	Spektrogram signala koji se sastoji od dve promenljive prostoperiodične komponente.	31
2.14	Najčešće korišćeni talasići.	32
2.15	Skalogram signala koji se sastoji od dve promenljive prostoperiodične komponente.	34
2.16	Wigner-Ville distribucija signala koji se sastoji od dve promenljive prostoperiodične komponente.	35
2.17	Blok dijagram za izračunavanje Hilbert-Huang transformacije.	36
2.18	Hilbert-Huang transformacija signala koji se sastoji od dve promenljive prostoperiodične komponente.	38

2.19	Sistem mlinskog postrojenja	43
2.20	(a) Ventilatorski mlin u termoelektrani Kostolac; (b) Zdrava udarna ploča; (c) Istrošena udarna ploča.	44
2.21	Sistem za akviziciju signala.	45
2.22	Zvučni signal snimljen u neposrednoj blizini mlina u vremenskom do- menu (gore) i frekvencijskom domenu (dole).	46
2.23	Snimljen zvučni signal i njegova anvelopa.	47
3.1	Eksperimentalno dobijena Gausova raspodela u odnosu na teorijsku.	50
3.2	Kontaminirana Gausova raspodela (gore) i Laplasova raspodela (dole) sa odgovarajućim QQ krivama.	51
3.3	Blok dijagram izvršavanja algoritma za detekciju kontaminacije.	53
3.4	Prva faza obučavanja: estimacija nominalnih kvantila.	55
3.5	Hilbertova transformacija nominalnog signala (gore), estimirana funkcija gustine verovatnoće (levo) i empirijska funkcija raspodele (desno).	58
3.6	Nominalni segment u odnosu na QQ_{nom} i QQ_{maes}	59
3.7	Nominalni snimak (gore), kriterijum J_1 sa granicom T_1 (levo) i kriterijum J_2 sa granicom T_2 (desno).	59
3.8	QQ kriva segmenta koji je kontaminiran govorom (levo) i segmenta koji sadrži impulsni šum (desno).	60
3.9	Deo testirajućeg snimka u vremenskom domenu (gore) i rezultat izvrša- vanja algoritma (dole).	61
3.10	QQ kriva nominalnog snimka sa diskriminacionom granicom α	64
3.11	Snimci kontaminirani govorom (levo) i odgovarajuća QQ kriva (desno). .	65
3.12	Snimci kontaminirani impulsnim šumom (levo) i odgovarajuća QQ kriva (desno).	66
3.13	QQ kriva sa dve klasifikacione linije.	67
3.14	Nominalni signal (gore) i 4 vrste šuma (dole) u frekvencijskom domenu. .	69
3.15	Klasifikacija koristeći optimalnu klasifikacionu hiperravan H_0 i granične hiperravni H_1 i H_{-1}	70
3.16	Binarno stablo za detekciju i klasifikaciju kontaminacije.	72
3.17	Stopa lažnih alarmi i promašene detekcije kao funkcija SNR.	73
3.18	Tačnost klasifikacije kao funkcija SNR.	74
4.1	Termini snimljenih zvučnih signala i broj radnih dana mlina od poslednjeg remonta za svaku sesiju snimanja.	80
4.2	Jednostavna Bajesova mreža.	85

4.3	Bejsova mreža za binarnu klasifikaciju.	87
4.4	Rezultati testiranja na 122 snimka u različitim stadijumima istrošenosti ploča.	89
4.5	Skriven Markovljev model.	90
4.6	Složen dinamički model.	90
4.7	Tok izvršavanja metode bazirane na proceni statističke distance.	92
4.8	Obučavanje metode bazirane na proceni statističke distance.	93
4.9	Testiranje metode bazirane na proceni statističke distance sa naznačenim periodom proteklom od poslednjeg remonta.	94
4.10	Mera istrošenosti udarnih ploča izračunata metodom baziranom na proceni statističke distance.	95
4.11	Ilustrativna validacija predložene metode bazirane na proceni statističke distance.	96
4.12	Tok izvršavanja metode bazirane na suptraktivnoj klasterizaciji.	97
4.13	Mera istrošenosti udarnih ploča izračunata metodom suptraktivne klasterizacije.	99

Lista tabela

2.1	Karakteristični nivoi pritiska zvuka.	17
2.2	Najčešće korišćena obeležja signala x u vremenskom domenu.	20
3.1	Rezultati detekcije kontaminacije.	60
3.2	Klasifikacija kontaminacije Neyman-Pearson testom.	67
3.3	Metoda nosećih vektora - rezultati detekcije za SNR=10 dB.	73
3.4	Metoda nosećih vektora - rezultati klasifikacije za SNR=10 dB.	74
4.1	Izdvojena obeležja signala ventilatorskog mlina u vremenskom i frekven- cijskom domenu.	81

Glava 1

Uvod

Potreba za tačnom i pouzdanom dijagnostikom mašina postoji otkad postoje kompleksni mehanički i električni sistemi [1]. Industrijska revolucija je sa sobom donela neverovatnu količinu novih mogućnosti proizvodnje, inovacija, poslova; međutim, takođe je otvorila vrata i novim problemima i opasnostima koji su postali očigledni tek godinama nakon što se industrijska proizvodnja ustalila. Kako su proizvodni kapaciteti i obimi postrojenja rasli, tako se i razarajući uticaj potencijalnih havarija povećavao predstavljajući opasnost ne samo po ljudske živote već i po životnu sredinu. Ovo je postalo nedvosmisleno jasno u drugoj polovini 20. veka kada su kvarovi u termoelektranama, nuklearnim elektranama i hemijskim fabrikama oduzeli desetine hiljada ljudskih života, uzrokovali trošak koji se meri u bilionima dolara i izazvali ekološku štetu koju će osetiti mnoge buduće generacije.

Jedna od najpoznatijih i najrazornijih havarija desila se 1986. godine u Černobilu kada je eksplozija nuklearne elektrane direktno odnela 31 ljudski život, dok je prekomerna radijacija uzrokovala smrt oko 9000 ljudi [2], a trošak sanacije ove katastrofe se meri u stotinama milijardi dolara. Danas, 30 godina kasnije, oblast poluprečnika 30 km oko elektrane je raseljena i zabranjena za život, a procenjeno je da će zbog prekomerne radijacije ta regija biti opasna za ljude narednih 20.000 godina. Tačan uzrok ove nesreće je kombinacija lošeg projektovanja elektrane, nedovoljnog poznavanja procesa kojim se upravlja i neadekvatne obuke operatera [3]. Ovo ukazuje na problem koji imaju mnoga postrojenja, a to je da se u cilju brže izgradnje i veće proizvodnje često zanemaruju osnovne bezbednosne mere.

Početak 21. veka je doneo mnoge promene na bolje što se tiče dostupnih algoritama i alata za unapređenje bezbednosti; međutim, razorne havarije još uvek nisu u potpunosti

uklonjene. 2010. godine *Deepwater Horizon* naftna platforma je eksplodirala zbog za-nemarivanja propisanih bezbednosnih mera i kasne detekcije curenja nafte, dok je 2011. godine eksplozija nuklearne elektrane u Fukušimi izazvala ekološku katastrofu po posle-dicama merljivu sa onom u Černobilu. Uzrok te eksplozije bio je kombinacija cunamija i jakog zemljotresa od kojih postrojenje nije bilo dovoljno zaštićeno. Iako je elektrana izgrađena na izuzetno trusnom području, a izveštaji koji su objavljeni godinama ranije upozoravali su na ovu opasnost, predlagane mere zaštite su ignorisane [4]. Sve ove ha-varije su ostavile neizbrisiv ekološki trag na celu planetu; međutim, pored katastrofalnih eksplozija koje su prilično retke, procenjeno je da se manje nesreće u industrijskim po-strojenjima dešavaju na dnevnom nivou izazivajući brojne povrede, bolesti i finansijsku štetu u iznosu od oko milijardu dolara godišnje [5].

Imajući u vidu sve ove primere jasno je da je razvijanje bezbednosnih algoritama od esencijalne važnosti za svaku proizvodnu delatnost, a blagovremena detekcija i klasifi-kaciju otkaza mašina ili istrošenosti komponenti ključan korak u prevenciji havarijskih situacija. Uprkos tome, zadatak detekcije hazardne situacije, dijagnoze uzroka i dono-šenje odluka o koracima koji će vratiti sistem u normalno, bezbedno, stanje je i dalje većinski ljudski manuelni posao [5]. Dodatni faktor koji značajno otežava tačnu dija-gnostiku je procena da velika moderna postrojenja mere do 1500 procesnih promenljivih svake sekunde, tako da je preopterećenje informacijama neminovno [6]. Ako se tu doda i statistika da je trećina troškova održavanja postrojenja rezultat lošeg ili nepotrebnog odr-žavanja [7], ne iznenađuje činjenica da naučna zajednica prethodnih decenija stavlja sve veći akcenat na razvijanje ekonomičnih pristupa održavanju mašina i na blagovremenu detekciju otkaza.

U nastavku uvodnog poglavlja biće ukratko opisan istorijat razvoja tehnika održavanja mašina sa posebnim osvrtom na rotacione aktuatore i specifičnosti vibracionih i akustičkih signala koji se koriste u te svrhe. Motivacija i doprinosi istraživanja vršenog u okviru ove disertacije biće jasno naznačeni, kao i dalja struktura teze.

1.1 Tehnike održavanja postrojenja

Promenom načina proizvodnje i automatizacijom industrijskih postrojenja došlo je i do prilagođenja pristupa koji inženjeri imaju prema servisiranju mašina, pa samim tim i do korekcija tehnika održavanja. Najstarija strategija održavanja je takozvano održavanje posle otkaza (engl. *breakdown maintenance*). Ona je masovno primenjivana u periodu pre Drugog svetskog rata kada je industrijska oprema bila jednostavnog dizajna, pa samim tim pouzdana i jednostavna za popravku [8]. Ova vrsta održavanja podrazumeva popravku ili

obnovu opreme tek nakon što ta oprema prestane sa radom i, kao takva, ona unosi prilično veliki trošak po postrojenje, kako zbog cene opreme koja mora da se menja, tako i zbog potencijalnih zastoja u proizvodnji i prekovremenih sati rada inženjera održavanja [7].

Posle Drugog svetskog rata pa sve do osme decenije 20. veka, kada kompleksnost industrijskih postrojenja počinje značajno da se povećava, troškovi održavanja postaju skuplji nego ostali operativni troškovi. Preventivno održavanje (engl. *preventive maintenance*) je strategija koja donekle uspeva da ublaži ove negativne aspekte i cilj joj je da otkrije potencijalne probleme pre nego što dođe do nekog katastrofnog otkaza. Ona se vodi pretpostavkom da će svaka mašina degradirati vremenom i da je potrebno korigovati njen rad pre nego što se to desi. Postoje različiti načini implementacije ove strategije i svi se vode procenom prosečnog životnog veka maštine i zakazivanjem periodičnih rutinskih inspekcija u skladu sa tim vremenskim intervalom. Ova periodična održavanja mogu da podrazumevaju sitne intervencije kao što su kalibracija ili podmazivanje određenih elemenata, ili veće radove, kao što je zamena radnih kola, koji podrazumevaju zaustavljanje delova sistema. Rezultat ovog tipa održavanja je značajno povećanje radnog veka maština i smanjenje potrebe za neplaniranim i prekovremenim radovima. Sa druge strane, ovaj režim periodične provere često ometa normalni rad postrojenja unosom nepotrebnih korekcija [9].

Početkom 90-ih godina 20. veka dolazi do promene paradigme u strategijama održavanja. Kompleksnost postrojenja nastavlja da raste, sve više se automatizuju procesi, uvode se stroži uslovi kvaliteta proizvoda, a potreba za bezbednošću postaje sve rigoroznija. Kao odgovor na ove zahteve javlja se prediktivno održavanje (engl. *predictive maintenance*) ili, kako se još naziva u literaturi, održavanje bazirano na stanju (engl. *condition-based maintenance*) [10]. Prediktivno održavanje podrazumeva korišćenje merenja i modernih tehnika obrade signala za preciznu procenu stanja opreme dok je postrojenje u funkciji. Uz tačnu estimaciju stanja maštine, opravke i zamene komponenti mogu da se organizuju tako da se maksimizira njen životni vek, a da se pritom ne ugrozi funkcionisanje postrojenja [11]. Jedan od glavnih izazova u implementaciji ovog vida održavanja je pronalazak pravih tehnologija merenja koje su dovoljno informativne za mašinu ili komponentu koja se posmatra, a dovoljno pouzdane i tačne da mogu da se koristite u algoritmima za estimaciju [12].

Primena prediktivnog održavanja predstavlja potpuno novu filozofiju u načinu ophodjenja prema postrojenju. Početkom 21. veka ova filozofija je počela da se menja i koriguje, i izraz „održavanje bazirano na riziku“ (engl. *risk-based maintenance*) počinje sve više da se koristi. Ovo predstavlja blagu nadogradnju prethodne strategije i podrazumeva ujedinjenje problema održavanja maština i brige o sigurnosti postrojenja. Ukratko, odr-

žavanje bazirano na riziku ima za cilj povećanje profitabilnosti proizvodnje uzimajući u obzir bezbednost industrijskog postrojenja i prevenciju potencijalnih ekoloških problema [13].

1.2 Estimacija stanja rotacionih aktuatora

Rotacioni aktuatori (kao što su mlinovi, ventili, pumpe, kompresori, turbine) su jedna od najprisutnijih klasa mašina i imaju izuzetno značajnu ulogu u industriji. Razvojem nauke i tehnologije rotacione maštine u industriji postaju veće, preciznije i više automatizovane; međutim i njihovi potencijalni otkazi i promene stanja postaju sve teži za detekciju. Zbog toga je potreba da se poveća pouzdanost u odnosu na otkaze izuzetno važna, a zbog specifičnosti njihove konstrukcije i načina funkcionisanja postoje čitave familije algoritama koje su specijalno razvijane baš za ovaj tip aktuatora [14].

Tri osnovna elementa u održavanju baziranom na stanju su: akvizicija podataka (odnosno prikupljanje i čuvanje podataka vezanih za stanje maštine), zatim obrada podataka (koja uključuje preprocesiranje i čuvanje informacija) i donošenje odluke (odnosno preporuka o daljim koracima održavanja kroz dijagnozu i prognozu). U zavisnosti od vrste maštine na kojoj se algoritmi primenjuju ovi koraci mogu da imaju određene specifičnosti. Što se tiče finalnog koraka koji se odnosi na donošenje odluke, odnosno prognozu stanja, postoje dva različita pristupa: pristup baziran na modelu (engl. *model-based*) i pristup baziran na podacima (engl. *data-driven*).

Prognoza bazirana na modelu podrazumeva kreiranje preciznog matematičkog modela koji verno opisuje fiziku ponašanja maštine, režima otkaza i promene stanja. Za rotacione aktuatore se često u literaturi koristi Paris-Erdoganov zakon [15] ili Formanove jednačine [16] prilikom modelovanja rasta napuklina kod rotirajućih elemenata, dok se numerički alati kao što su analiza konačnih elemenata [17] koriste za modelovanje pritiska i naprezanja materijala. Ovi algoritmi za procenu stanja zahtevaju prilično malu količinu izmerenih podataka i, ako se korektno sprovedu, mogu da imaju jako veliku tačnost; međutim, u industriji se prilično retko primenjuju zbog velikih kompleksnosti egzaktnih modela i činjenice da je većina otkaza jedinstvena za svaku vrstu maština, pa je same algoritme jako teško generalizovati [18].

Pristup baziran na podacima podrazumeva kreiranje matematičkog modela direktno koristeći rutinski prikupljene podatke i merenja. Ovi algoritmi ne zahtevaju poznavanje egzaktnog modela i fizike koja opisuje proces; međutim, za njihovu implementaciju neophodna je jako velika količina merenja i direktno se uzdaju u šablone podataka prethodnih događaja da bi predvideli buduće događaje. U literaturi su trenutno veštačke neuralne

mreže najpopularnija prognostičarska metoda bazirana na podacima. Poznate su mnoge dobre osobine ove metode kao što su brze performanse [19] i sposobnost da modeluju kompleksne fenomene; međutim, mnogi autori im zameraju smanjenje transparentnosti prilikom donošenja odluka kada se kompleksnost modela povećava [20]. Osim neuralnih mreža, popularne tehnike bazirane na podacima su čestični filtri za predviđanje rasta pu-kotina na rotirajućim elementima [21], zatim skriveni Markovljevi modeli [22], Bajesove mreže [23], i sl.

Svi algoritmi bazirani na podacima imaju za zadatak da od prikupljenih obeležja donesu zaključak o stanju mašina. Dakle, da bi se uspešno implementirali prvo je potrebno snimiti informativna merenja, pa iz njih izdvojiti relevantna obeležja. Često se dešava da sama merenja budu prilično zašumljena ili da izdvojena obeležja budu nedovoljno informativna, što povećava kompleksnost neophodnog algoritma klasifikacije i smanjuje šansu za tačnom predikcijom. Zato je od izuzetno velike važnosti precizno proceniti koji tip merenja je najinformativniji za problem koji se procenjuje i obezbediti minimalnu zašumljenost korišćenih podataka [24]. U ovom aspektu specifičnosti rotacionih aktuatora dolaze do izražaja kako zbog njihove ciklostacionarne prirode tako i zbog periodičnih udara koje proizvode. Minimalno destruktivne tehnologije kao što su vibraciona i akustička analiza su se pokazale kao izuzetno informativne za ovu familiju mašina [25].

1.3 Vibraciona i zvučna dijagnostika

Zvuk i vibracija se jako dugo koriste za procenu unutrašnjeg stanja mašina i građevina, čak i onda kada ne postoje automatizovani algoritmi koji bi obradili ove signale u cilju donošenja odluke. Tako, na primer, automehaničari često slušaju zvuk motora kako bi detektovali unutrašnje defekte koji utiču na promenu njihovog zvučnog potpisa. Cilj razvijanja algoritama za detekciju stanja je prebacivanje ovih tehnika iz domena subjektivnog dojma u domen naučne discipline.

Vibraciona analiza je uveliko uspostavljena kao primarni prognostičarski alat za rotacione aktuatore u industriji [26]. Ona se koristi za procenu operacionog i mehaničkog stanja mašine, a najveća prednost je sposobnost da detektuje otkaze pre nego što postanu toliko opasni da izazovu neplanirana isključenja. Razlog česte upotrebe vibracione analize u ove svrhe je taj što je vibracioni mehanizam mašina prilično dobro opisan u literaturi i promene u signalu vibracije mogu lako da se pripisu dinamičkim karakteristikama rotacionih aktuatora i njihovim otkazima. Signal vibracije može da detektuje istrošenost komponenti, slomljene zupčanike, kao i neusklađenost i neuravnoteženost ležišta [27], pa se samim tim može koristiti za detekciju otkaza, procenu stanja, ali i proveru pravilno

obavljenog održavanja.

Postoji mnogo studija koje objašnjavaju princip generisanja vibracije kod rotirajućih elemenata [28], a osnovni doprinos karakterističnom vibracionom potpisu ovih mašina imaju ležišta koja vibriraju zbog promenljive raspodele tereta ili zbog prisustva defekta u aparaturi. Periodična varijacija krutosti je takođe česti uzrok vibracija, čak i ako je ležište savršeno poravnato [29]. Sa druge strane, pojavom defekta, bilo distribuiranih ili lokalnih, nivo vibracije se značajno povećava [30]. Distribuirani defekti obuhvataju hrapavost, talasastost, neusklađenost kontakta i mogu da budu izazvani greškom u proizvodnji, lošom instalacijom ili naprosto istrošenošću radnih kola. Oni su značajni ne samo za detekciju stanja, već i za proveru kvaliteta instalacije. Lokalni defekti su uglavnom u formi neke lokalne napukline ispod površine koja se širi sve dok ne izazove otkaz. Ovakav defekt izaziva pojavu periodičnog pulsa kratkog trajanja i može se detektovati bilo u vremenskom domenu, posmatranjem pojave periodičnog pika u signalu vibracije, ili u frekvencijskom domenu u vidu eksitacije prirodne frekvencije mašine [31]. Glavna mana korišćenja vibracionih signala prilikom detekcije stanja rotacionih aktuatora leži u činjenici da se senzori (akcelerometri) često postavljaju direktno na kućište aparature, radi veće preciznosti, tako da ovaj pristup spada u invazivne načine snimanja i u nekim slučajevima može da utiče na funkcionisanje mašine [32].

Osim signala vibracije, često se za dijagnozu stanja rotacionih mašina još koriste i signali akustičke emisije (AE) i signali zvuka. Na sva tri tipa merenja direktno utiče način vibracija mašina, samo je kod akustičke emisije i signala zvuka ta vibracija indirektno izmerena njenim prenosom kroz vazduh u vidu akustičkih talasa. Signali zvuka se odnose na akustičke talase čije su frekvencije između 50 Hz i 20 kHz, a akustička emisija se meri na izuzetno visokim frekvencijama koje se nazivaju i supersoničnim. Dok su signali vibracije i akustičke emisije izuzetno otporni na šum, signali zvuka to nisu, pa se zato ređe koriste.

Korišćenje akustičke emisije za detekciju napuklina na neinvazivan način se pojavilo kao ideja još sredinom 20. veka. Akustička emisija je fenomen generisanja talasa zbog oslobođanja energije usled menjanja strukture čvrste materije zbog mehaničkog ili temperaturnog stresa. Frekvencije na kojima se javljaju ove informacije su između 1 kHz i 1 MHz, a senzori koji detektuju akustičke emisije su piezoelektričnog tipa i uglavnom mogu da detektuju talase na frekvencijama iznad onih koje može da čuje ljudsko uvo (supersonične frekvencije od 20 kHz do 1 MHz). Mnoge analize su rađene u literaturi i ustanovljeno je da, osim sposobnosti da se detektuje lokalni deformitet u vidu pukotine, akustička emisija može taj događaj da detektuje pre nego što se pukotina ispolji na površini [33]. Primena akustičke emisije za nedestruktivno testiranje se može naći u broj-

nim segmentima industrije uključujući i rafinerije, cevovode, elektrane, letelice, mlinove i strukture tipa mostova, kranova i sl. Sa druge strane, promena stanja mašina može teško da se detektuje na ovaj način [34] i u tom smislu su i dalje superiorniji signali vibracije.

Osim akustičnih emisija koje se odnose na komponente akustičkog signala na supersoničnim frekvencijama, utvrđeno je da merenje običnih zvučnih signala takođe može da donese jako korisne informacije o stanju rotacione mašine. Za snimanje ovih podataka dovoljan je običan mikrofon i, kao i kod akvizicije akustičke emisije, beskontaktni je tip snimanja, tako da nije destruktivan po samu mašinu. Mnoge uporedne analize korišćenja zvuka i vibracije su rađene početkom 21. veka [35] i zaključeno je da mikrofon, kao i akcelerometar, može da detektuje stanje mašine u vidu lokalnog ili decentralizovanog defekta i da, u nekim slučajevima, to može da uradi dosta brže od senzora vibracije [36]. Problem kod mikrofona, međutim, je u tome da je izuzetno podložan okolnom šumu. Naime, osim zvučnog potpisa same mašine koja je od interesa, mikrofon će snimiti i zvuk svih mašina koje se nalaze u okolini, i na taj način će odnos signal-šum biti mnogo lošiji nego kod signala vibracije. Upravo ova podložnost okolnom šumu je razlog zašto se signali zvuka nisu koristili za potrebe prediktivnog održavanja u industriji.

Dijagnostiku stanja rotacionih aktuatora najbolje je obaviti analizom vibracionih karakteristika mašine, tako da su signali koji nose tu informaciju (vibracioni, zvučni i akustička emisija) logičan izbor za rešavanje ovog problema [37]. S obzirom da je od svih njih signal zvuka najosetljiviji na šum, on se i najređe koristi u realnim industrijskim okruženjima gde je izloženost kontaminaciji neminovna. Međutim, ovaj veliki nedostatak zvučnog signala je ujedno i njegov najveći benefit. Naime, velika osetljivost na vibracione promene okoline garantuje brzu i efikasnu detekciju, a dodatni signali koji bivaju snimljeni u vidu šuma ne predstavljaju ništa drugo nego dodatne informacije o dešavanju u okolini same mašine. Sve ovo ukazuju na činjenicu da bi uvođenje zvučnih signala u industrijska postrojenja unapredilo dosadašnje tehnike prediktivnog održavanja rotacionih aktuatora i unelo dodatne informacije u vidu detekcije i klasifikacije različitih događaja. Međutim, pre nego što se to desi neophodno je razviti algoritme koji koriste akustične signale i koji su otporni na stacionaran šum, a takođe i razviti sistem za robustifikaciju takvih algoritama tako što se spreči delovanje nestacionarne kontaminacije na rezultat odlučivanja.

1.4 Motivacija i doprinos

Cilj ove disertacije je dvojak: sa jedne strane teži se unapređenju rada rotacionih aktuatora razvijanjem novih algoritama za estimaciju stanja, a sa druge strane se pospešuje

korišćenje akustičkih signala u realnom industrijskum okruženju razvijanjem adaptivnih tehnika za detekciju kontaminacija. Još jedna stvar koju treba imati na umu je težnja da se finalna struktura estimatora stanja rotacionih aktuatora korišćenjem akustičkih signala implementira na jednostavnom mikrokontrolerskom uređaju. Time bi cena implementacije ovakvog detektora stanja bila prilično niska, a hardverska postavka jednostavna.

U smislu detekcije stanja mašina, postoji pregršt algoritama koji su razvijani u literaturi, i veliki broj njih je testiran u realnim industrijskim okruženjima. Sva ta rešenja se sastoje iz nekoliko standardnih koraka: preprocesiranje signala, zatim izdvajanje obeležja i na kraju donošenje zaključaka metodama prepoznavanja oblika i klasifikacije. Najčešće su ovi algoritmi razvijani sa ciljem specifičnog načina implementacije datih koraka za svaku aparaturu i za svaki problem ponaosob. Ono što nedostaje u literaturi je generalizovan predlog rešenja detekcije stanja za široku familiju aktuatora. Sa druge strane, većina algoritama za detekciju stanja vrši diskretnu klasifikaciju. To znači da iz ograničenog skupa mogućih stanja mašine, na osnovu merenog signala, detektuje u kom od tih skupova se mašina trenutno nalazi. Rešenja koja vrše kontinualnu procenu promene stanja u vidu praćenja istrošenosti komponenti mašine su izuzetno retka u literaturi, a zbog komplikovanog načina testiranja tih algoritama, često su verifikovani samo na simuliranim modelima, a ne i na pravim industrijskim aparaturama.

Rotacioni aktuatori su najprisutnija familija aktuatora u industriji, a rotirajući elementi u okviru njih imaju vrlo karakterističan ciklostacionaran vibracioni i zvučni potpis. U okviru ove disertacije su predloženi algoritmi koji prate promenu istrošenosti elemenata tako što, na osnovu izdvojenih obeležja, formiraju kontinualnu metriku čija vrednost raste kako se elementi više troše. Proces predobrade, izdvajanja obeležja i računanja metrike je verifikovan na realnim zvučnim signalima ventilatorskog mlina snimanim u termoelektrani Kostolac A1 u periodu od nekoliko meseci. Ovi koraci u implementaciji detektora stanja su generalizovani, tako da se mogu primeniti i na drugim vrstama rotacionih aktuatora.

U smislu primene akustičkih signala u industriji, to je aktuelan problem i njihova velika osetljivost na šum i dalje nije adekvatno rešena. Sa druge strane akustički signali se masovno koriste za ambijentalnu analizu, analizu scenarija u prostorijama pametnih zgrada, *internet-of-things* tehnologijama i slično. U svim tim aspektima njihova velika podložnost šumu je tumačena kao pozitivna osobina, jer na taj način akustički signali upijaju više informacija, pa i omogućavaju opširniju analizu događaja.

U okviru ove disertacije pomenuti pristupi obradi akustičkih signala su usvojeni i primjenjeni u industrijskom okruženju. Razvijen je adaptivni algoritam koji detektuje pojavu kontaminacije signala. Na taj način se robustificuju estimatori stanja koji koriste aku-

stičke signale tako što sprečavaju da zašumljeni odbirci utiču na procenu. Time je glavni problem primene akustičkih signala u industriji otklonjen. Takođe, u duhu akvizicije što veće količine informacija o ambijentalnim dešavanjima, razvijeni su algoritmi koji ne samo da detektuju kada je došlo do kontaminacije akustičkog signala, već i klasifikuju koja kontaminacija je u pitanju. Na ovaj način otvara se prostor ka proširenju algoritama za detekciju stanja na analizu scenarija u industrijskim okruženjima. I ovde su algoritmi testirani na ventilatorskom mlinu u termoelektrani Kostolac A1.

1.5 Struktura teze

Ostatak teze je podeljen u tri dela. Prvo je dat pregled karakteristika zvučnog signala sa algoritmima koji se najčešće koriste za njegovu obradu u glavi 2, a glavni doprinosi teze prikazani su u poglavljima 3 i 4. Pregled oblasti i novih rešenja algoritama za detekciju i klasifikaciju kontaminacije je prikazan u glavi 3, dok je predlog novih algoritama za detekciju stanja prikazan je u glavi 4.

U glavi 2 opisane su karakteristike zvučnog signala i njihova primena. Prvenstveno, dat je kratki pregled osobina zvuka, načina njegovog nastanka i prostiranja. S obzirom da je veliki broj postojećih tehnika za analizu zvučnog signala motivisan načinom na koji ljudsko uvo reaguje na zvuk, u kratkim crtama je dat opis načina na koji ljudi vrše akviziciju ovih signala. Najpopularnije metode za obradu i analizu zvučnog signala su opisane, a predloženi su i načini na koje mogu da se izdvoje korisne informacije iz signala u vidu obeležja posle primene svake od opisanih transformacija. Metode kao što su *Wavelet* analiza, Hilbert-Huang i Wigner-Ville transformacije su spomenute prilikom opisa dvodimenzionalnih tehnika analize zvuka i one su jako često korišćene u prediktivnom održavanju. Kepstralna analiza, sa druge strane, kao metoda analize u frekvencijskom domenu, nema veliku primenu u industriji; međutim, izuzetno je korišćena prilikom obrade i prepoznavanja govora, tako da je i njen kratki opis dat u okviru ovog poglavlja. Osim načina obrade zvučnog signala dat je i kratak osvrt na istorijat korišćenja ovog tipa merenja u industriji, a opisan je i konkretan način akvizicije zvučnog signala u termoelektrani Kostolac A1 u okolini ventilatorskog mlina. Ova studija slučaja biće korišćena za testiranje svih daljih algoritama koji su predloženi u ovoj tezi.

Glava 3 je skoncentrisana na algoritme koji se tiču detekcije kontaminacija u cilju robustifikacije metoda estimacije stanja na bazi signala zvuka. Ova oblast se uglavnom poklapa sa oblašću detekcije loših podataka koja se rapidno razvijala u poslednjih 10 godina i odnosi se na detekciju zlonamernih pokušaja izmene merenih podataka u cilju napada na infrastrukturu industrijskih sistema. Pregled ovih algoritama je dat uz osvrt na

potencijalni način njihovog korišćenja u prediktivnom održavanju. Osim problema detekcije kontaminacija, u ovoj glavi su razvijane i tehnike klasifikacije nestacionarnog šuma u cilju proširenja primene algoritama za analizu scenarija u industrijskim postrojenjima. Posebno su prikazane QQ krive kao glavni alat koji se koristi u ovom poglavlju. Dat je opis novog algoritma za detekciju šuma, kao i opis algoritama za klasifikaciju kontaminacije Neyman-Pearson testom i metodom nosećih vektora. Osim opisa ova tri algoritma koja su razvijena u okviru doktorske teze, prikazani su i njihovi rezultati na primeru ventilatorskih mlinova u termoelektranama, uz mogućnost proširenja na bilo koji aktuator koji proizvodi ciklostacionarne vibracije.

Finalni algoritmi za detekciju stanja rotacionih aktuatora korišćenjem akustičkog signala predloženi su u glavi 4. Prvo su opisane tehnike za pretprocesiranje signala i izdvajanje obeležja koje su primenjene na realnim signalima mlinova iz termoelektrane, ali mogu se koristiti za bilo koji tip rotacionog aktuatora. Tri metode estimacije stanja su dalje prikazane. Jedna se bazira na probabilističkoj metodi Bajesovih mreža. Zbog komplikovane implementacije ovakve vrste praćenja stanja ovaj algoritam, iako je testiran na realnim signalima, nije preporučljiv za praktičnu implementaciju. Iz tog razloga predložena su još dva algoritma koja, koristeći standardne tehnike prepoznavanja oblika (redukciju dimenzija i klasterizaciju) uspevaju na računarski jednostavan način da procene stanja rotacionih aktuatora. Za finalnu detekciju stanja predložene su metrike koje oslikavaju nivo istrošenosti elemenata rotacionih aktuatora i, u skladu sa tim, omogućavaju kontinualno praćenje stanja maštine.

Mnogi pojmovi, imena i skraćenice u ovoj disertaciji su preuzeti direktno iz stručne literature na engleskom jeziku. Često adekvatni nazivi na srpskom jeziku ne postoje i tada su korišćeni prevodi koje je autor teze procenio za adekvatne. U tim slučajevima je u zagradama naznačeno kako se nazivaju ti pojmovi u originalu. Takođe, u slučaju kada imena stranih naučnika koja su korišćena u disertaciji nisu ustaljena u srpskom jeziku, način pisanja imena će biti ostavljen u svom originalnom obliku.

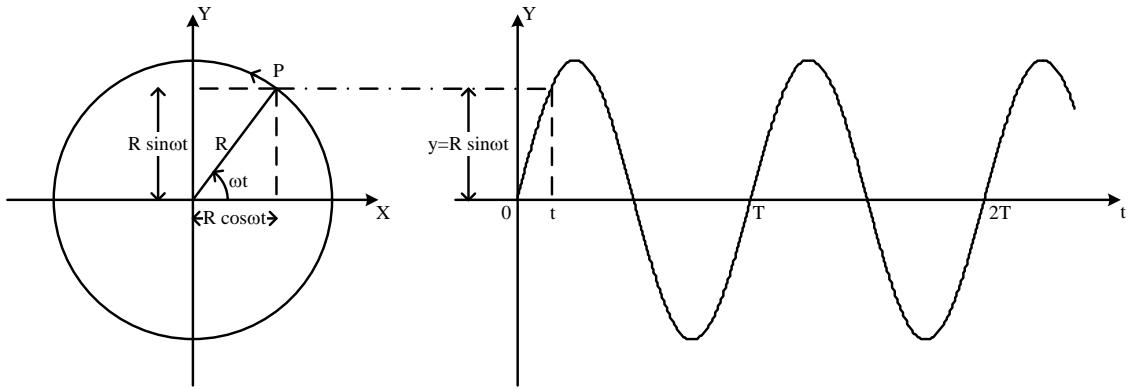
Glava 2

Akustički signali u prediktivnom održavanju

Akustika je nauka koja se bavi izučavanjem zvuka, njegovim nastankom, prenosom kroz čvrste materijale i fluide i bilo kojim drugim fenomenom koji je uključen u njegovu propagaciju kroz različite medijume. Reč akustika je nastala od grčke reči *ακουστικός* što, u grubom prevodu, znači *čuti*. Zvuk nastaje tako što vibrirajući objekat uzrokuje propagaciju mehaničkih talasa kroz elastični medijum izazivajući pomeraj i vibriranje čestica.

S obzirom na veliki uticaj zvuka u svakodnevnom životu ljudi, začeci akustičkih specifikacija materijala i instrumenata, kao i spekulacije o prirodi zvuka, se protežu mnogo pre nego što je standardna nauka ušla u koštač sa tim problemima. Tako se prvi pisani skup akustičkih specifikacija može naći u Starom zavetu [38], a već su Pitagora u 6. veku p.n.e. i Aristotel u 4. veku p.n.e. uspeli da objasne prirodu harmoničnih tonova i načina prostiranja zvučnih talasa. Takođe, začetnik arhitektonske akustike Vitruvius je oko 20. godine p.n.e. predložio postavljanja bronzanih vaza oko pozornice koje bi obavljale ulogu pojačavača zvuka. Posle srednjeg veka, zajedno sa munjevitim razvojem nauke, javlja se i moderni pristup izučavanju akustike. Počevši od Galilea Galileja i njegovih zakona vibrirajućih niti, preko Njutna i njegove procene brzine talasa u čvrstim telima, signali zvuka postaju prisutni i primenjivani u gotovo svim granama nauke. Opsežan opis razvoja moderne akustike može se naći u kulnoj knjizi *Teorija zvuka* koju je napisao dobitnik Nobelove nagrade Rayleigh 1945. godine [39] koja i dalje služi kao osnova akustičkog inženjerstva.

Danas je korišćenje zvuka prisutno u raznim granama nauke, inženjerstva i umetnosti [40] kao što su bioakustika, analiza seizmičkih talasa, buka, vibracija, muzika, komuni-



Slika 2.1: Jednostavno harmonijsko kretanje čestice.

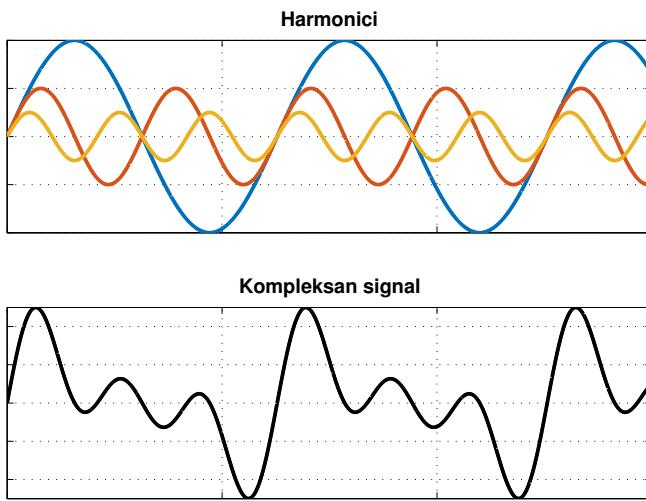
kacija, psihoakustika, podvodna akustika, itd. Sasvim je prirodno, dakle, da akustička dijagnostika već uveliko ulazi u industrijska postrojenja i algoritme održavanja. U okviru ovog poglavlja biće kratko opisane osnovne osobine zvuka, način prostiranja i način na koji ga ljudsko uvo detektuje. Dalje, biće opisani osnovni algoritmi za obradu zvuka koji se često koriste ne samo kod industrijske dijagnostike već i za mnoge druge potrebe. Posle toga biće opisan kratak istorijski osvrt na zvučne signale u industriji i na kraju će biti predstavljeni akustički signali snimljeni u realnom industrijskom postrojenju, konkretno zvukovi mlina u termoelektrani Kostolac A1.

2.1 Osobine zvuka

Vibracija u mašinama i mehaničkim strukturama rezultuje oscilatornim kretanjem koje se propagira kroz vazduh ili tečnost i naziva se zvuk. On putuje kroz elastični medijum brzinom koja je karakteristična za taj medijum. Propagacija zvuka u svojoj osnovi predstavlja kretanje talasa, ali za razliku od elektromagnetnih talasa (kao što su svetlosni, rendgenski i gama talasi), akustički talas je u svojoj prirodi mehanički fenomen [38]. Iz tog razloga je za prostiranje zvučnog talasa neophodan elastični medijum kao što je gas, tečnost ili čvrsto telo.

2.1.1 Jednostavno harmonijsko kretanje

Najjednostavniji tip oscilacija kod zvuka je jednostavno harmonijsko kretanje za koje se može pokazati da je sinusoidalno u vremenu. Ovakav vid kretanja je od velikog interesa u nauci zato što je jednostavan za matematičku manipulaciju, ali je i od velike praktične važnosti. Naime, većina muzičkih instrumenata proizvodi tonove koji su približno periodični i sadrže jednostavne harmonike. Takođe, neke mašine, kao što su električni motori



Slika 2.2: *Harmonici na učestanostima ω_0 , $2\omega_0$ i $3\omega_0$ (gore) i suma sva tri harmonika (dole).*

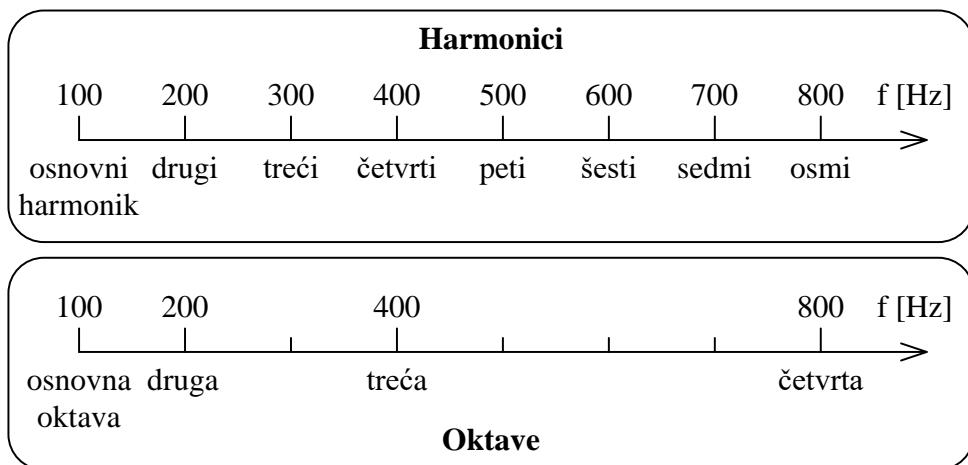
i ventilatori, proizvode zvukove koji se sastoje od čistih tonova.

Jednostavno harmonijsko kretanje predstavljeno je na slici 2.1. Ako prepostavimo da se čestica P kreće po kružnici poluprečnika R oko centra O brzinom ω , i ako je u trenutku $t = 0$ vektor OP u ravni sa OX osom, onda je posle t sekundi ugao između vektora OP i X ose jednak ωt . Shodno tome, projekcija pozicije čestice P na X osu je $x = R \cos \omega t$, a projekcija na Y osu je $y = R \sin \omega t$. Ova promena projektovane pozicije čestice na X ili Y osu se zove jednostavno harmonijsko kretanje, a ω [rad/s] se naziva osnovna kružna učestanost. Jasno je da se ovo kretanje ponavlja svaki put kada je $\omega t = 2\pi$. Frekvencija f [Hz] se dobija kao $f = \omega/2\pi$, a perioda T [s] se dobija kao $T = 2\pi/\omega$.

Muzički instrumenti i mašine uglavnom proizvode nekoliko čistih tonova istovremeno, s tim što mašine proizvode i zvuk koji se ne može okarakterisati kao jednostavni harmonik već je stohastički u vremenu i naziva se šum. Kompleksan signal koji se sastoji od nekoliko harmonika može se videti na slici 2.2. Harmonici predstavljaju celobrojni umnožak neke učestanosti koju nazivamo osnovni harmonik. Tako, na primer, ako osnovni harmonik ima učestanost ω_0 , drugi harmonik se nalazi na učestanosti $2\omega_0$, treći na $3\omega_0$, itd.

Poznato je da se svaki periodičan talas može predstaviti pomoću jednostavnih sinusoidalnih talasa različitih frekvencija u vidu Furijeovih redova. S tim u vidu korisno je objasniti određene pojmove koji se često javljaju prilikom opisivanja kompleksnih zvučnih talasa: harmonici i oktave.

Podela na harmonike je od izuzetne praktične važnosti zato što se oni prirodno ja-



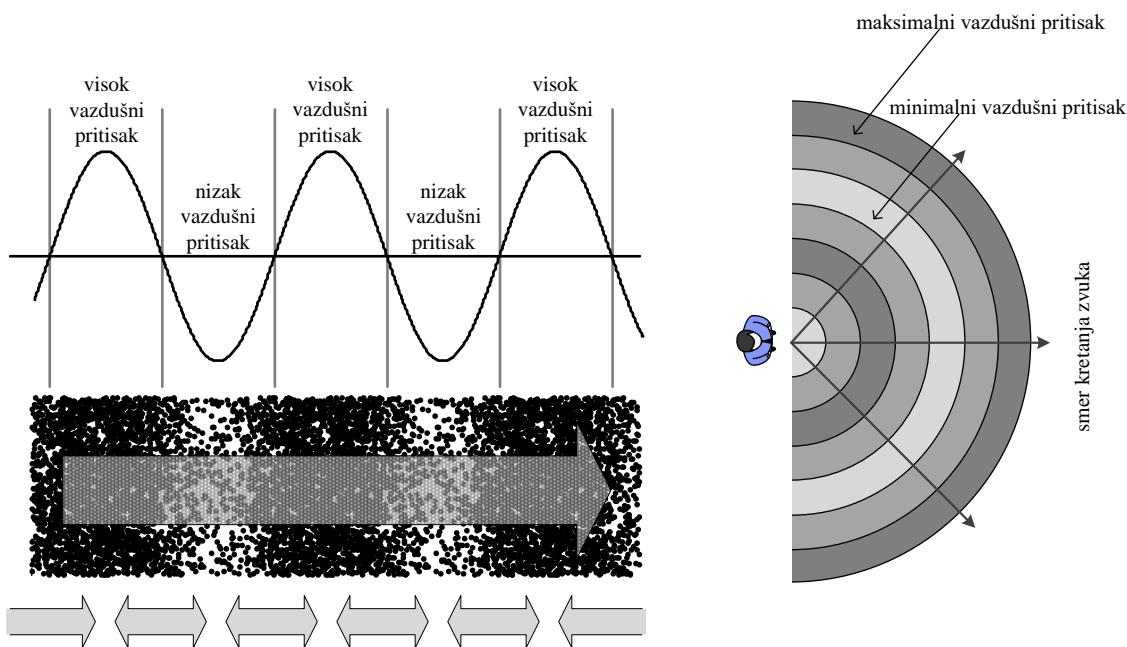
Slika 2.3: *Poređenje harmonika i oktave za osnovnu frekvenciju 100 Hz [41]*

vljaju svaki put kada postoji neki dugačak linearni rezonator (kao što je žica na violini), ali je i matematički korisna zato što se već pomenutim Furijeovim redovima kompleksni talasi rastavljaju na harmonike. Takođe, prilikom analize zvuka koji emitiše rotacioni ak-tuator često postoje 8 do 10 prostoperiodičnih komponenti koje predstavljaju celobrojne umnožke osnovne učestanosti. Čak i aperiodični zvukovi, kao što je zvuk mlaznog motora, mogu da se opišu dominantnim harmonicima [38].

Oktave takođe predstavljaju podelu frekvencija ali u razmeri 2:1. Tako na primer ako imamo osnovnu frekvenciju f_0 , sledeća viša oktava se nalazi na duplo većoj frekvenciji $2f_0$, a sledeća niža oktava se nalazi na duplo manjoj frekvenciji $0.5f_0$. Oktave su izuzetno važne u muzičkoj terminologiji zato što logaritamska podela frekvencija više odgovara karakteristikama ljudskog uva nego linearna podela harmonika. Odnos oktave i harmonika u odnosu na zajedničku osnovnu frekvenciju od 100 Hz može se videti na slici 2.3.

2.1.2 Prostiranje zvuka

Propagacija zvučnog talasa se vrši pomeranjem čestica u datom medijumu. Kako energija talasa putuje u određenom pravcu, čestice medijuma osciluju oko ravnotežnog položaja kreirajući regije kompresije i razređenosti, kao na slici 2.4. Kompresija se dešava na mestima visokog pritiska, dok se razređenost dešava na mestima niskog pritiska. U zavisnosti od medijuma kroz koji se zvučni talas prenosi, kretanje čestica može da bude longitudinalno ili transverzalno. Zvuk se prostire longitudinalnim talasima kroz gasove i tečnosti, i tada se čestice kreću u pravcu kretanja talasa. Transverzalni talasi se, sa druge strane, javljaju kada se zvuk prostire kroz neke čvrste medijume, i tu čestice osciluju normalno u odnosu na pravac prostiranja talasa [41].



Slika 2.4: Prikaz prostiranja zvučnog talasa kroz vazduh

Brzina kojom se zvučni talasi prostiru zavisi od gustine i temperature medijuma koji ih prenosi. Što je gušći medijum, to je veća brzina prostiranja talasa, tako da se zvuk najbrže prostire kroz čvrsta tela, zatim kroz tečnosti, pa najsporije kroz gasove. Takođe, kako se temperatura okoline povećava, tako se povećava i brzina kretanja zvučnog talasa. Tako, na primer, brzina zvuka kroz vazduh na nadmorskoj visini 0 m, pri temperaturi od 20 °C iznosi $c_0 = 343 \text{ m/s}$.

Ako se posmatra u dve dimenzije, zvučni talas se prostire pravolinijski dok ne nađe na neku prepreku u vidu objekta ili promene u medijumu. U tom slučaju može da se desi refleksija, difrakcija, refrakcija ili apsorpcija talasa. Refleksija se dešava kada talas nađe na prepreku. Tada prepreka apsorbuje deo energije talasa, a ostatak se reflektuje. Echo je tipičan primer refleksije talasa. Refrakcija se dešava kada talas putuje iz jednog medijuma u drugi koji izaziva promenu brzine i savijanje talasa. Primer refrakcije je kada zvučni talas koji putuje kroz vazduh nađe na zid. Naravno, svi ovi događaji mogu da se dese pojedinačno ili odjednom u zavisnosti od okruženja kroz koje se talas prostire.

U otvorenom prostoru u kome nema uticaja okolnih objekata zvuk se od izvora propagira uniformno u svim pravcima, kao na slici 2.4. Intenzitet zvuka slabi kako se udaljava od izvora i to obrnuto proporcionalno kvadratu odstojanja. Iz tog razloga je izuzetno značajno snimati zvučni signal što je moguće bliže samom izvoru zvuka, jer i jako male udaljenosti mogu da donesu značajno slabljenje u kvalitetu snimka.

2.1.3 Zvučni pritisak

Očigledno je iz slike 2.4 da je propagacija talasa periodičnog karaktera. Ako je T perioda oscilovanja, a c_0 brzina zvuka kroz datu medijum, onda se talasna dužina zvuka definiše u metrima kao

$$\lambda = c_0 T. \quad (2.1)$$

Pritisak $p(t)$ [N/m^2] duž prostiranja talasa na nekom mestu x se tako može izračunati kao

$$p(t) = P \cos \left[2\pi \left(\frac{x}{\lambda} - \frac{t}{T} \right) \right], \quad (2.2)$$

gde je P amplituda zvučnog pritiska. Kod zvučnih talasa koji se prostiru kroz vazduh zvučni pritisak u bilo kojoj tački je razlika ukupnog pritiska i normalnog atmosferskog pritiska. Samim tim on je promenljiv u vremenu i može da bude pozitivan ili negativan u odnosu na normalni atmosferski pritisak.

Zbog promenljive prirode zvučnog pritiska u vremenu, pogodno je dati reprezentaciju tog pritiska jednim brojem koji bi karakterisao neku vrstu prosečne vrednosti pritiska u vremenu. Računanje aritmetičke sredine na dovoljno dugačkom vremenskom intervalu bi uvek rezultovalo nultoj vrednosti, tako da nam ta veličina nije od interesa. Veličina koja se često koristi kao mera jačine zvučnog pritiska je efektivna vrednost (engl. *root mean square value*) pritiska

$$p_{rms} = \sqrt{\frac{1}{T} \int_0^T p^2(t) dt}. \quad (2.3)$$

U specijalnom slučaju kada je zvučni talas jednostavni harmonik kao na slici 2.4, tada je promena pritiska u vremenu oblika čiste sinusoide $p = P \cos \omega t$, a koren srednje kvadratne vrednosti pritiska iznosi $p_{rms} = P/\sqrt{2}$.

Opseg jačine zvuka, odnosno zvučnog pritiska, koji može da se oseti u praksi je veoma veliki, tako da se češće koriste logaritamske razmere za opisivanje jačine zvuka umesto linearnih. Najčešća mera jačine zvuka je decibel [dB] i on predstavlja odnos izmerenog pritiska, p_{rms} , i referentnog pritiska, p_{ref} . Tako se nivo zvuka u decibelima računa kao

$$L_p = 20 \log_{10} \frac{p_{rms}}{p_{ref}}, \quad (2.4)$$

gde referentni pritisak predstavlja granicu čujnosti i jednak je $p_{ref} = 0.00002 \text{ N}/\text{m}^2$. Opseg jačine zvukova koji ljudi mogu da detektuju bez oštećenja sluha prikazan je u tabeli 2.1.

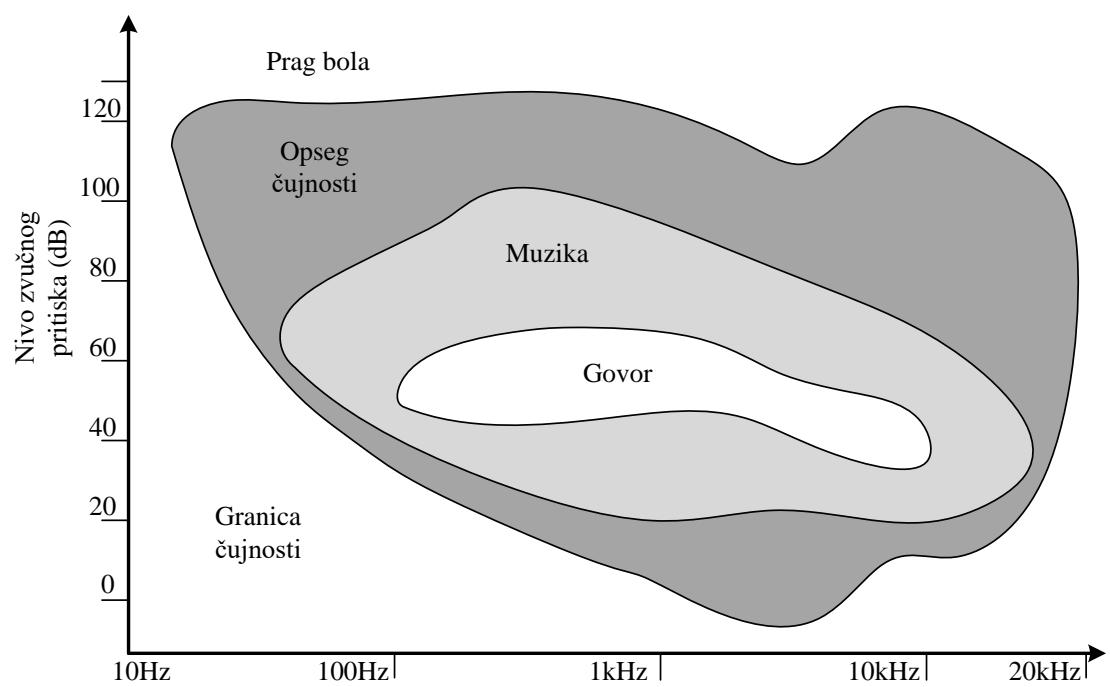
Tabela 2.1: Karakteristični nivoi pritiska zvuka.

$p_{rms} [\text{N/m}^2]$	$L_p [\text{dB}]$	Događaj
0.00002	0	Granica čujnosti
0.00063	30	Šuškanje lišća na udaljenosti 20 m
0.03557	65	Kucaća mašina na udaljenosti od jednog metra
0.20000	80	Kamion na udaljenosti 20 m
2.00000	100	Kosilica
20.0000	120	Poletanje mlaznog aviona na udaljenosti 500 m
200.000	140	Granica bola
2000.00	160	Trenutno oštećenje sluha

2.1.4 Frekvencijski opseg zvuka

Još je Furije pre 200 godina pokazao da zvučni signali mogu da se razlože na frekvencijske komponente i ustanovljeno je da ljudsko uvo deluje kao neka vrsta frekvencijskog analizatora. Opseg frekvencija koje ljudsko uvo može da čuje je između 15 Hz i 16 000 Hz, ali je najosetljivije na zvuk koji se nalazi na frekvenciji od oko 4000 Hz [26]. Frekvencije zvuka koje su suviše niske da bi ih ljudsko uvo detektovalo se zovu infrasenične, frekvencije koje su suviše visoke se zovu supersonične.

Sposobnost ljudskog uva da detektuje zvuk zavisi ne samo od frekvencije zvuka već i od jačine. Tako na frekvencijama manjim od 200 Hz ljudsko uvo ne čuje zvuk dobro i potreban je jako visok nivo pritiska da bi bio detektovan. Normalni ljudski govor se dešava u opsegu između 100 Hz i 4000 Hz, gde su samoglasnici uglavnom na niskim i srednjim delovima ovog opsega, a suglasnici na visokim frekvencijama. Sa druge strane frekvencijski opseg koji proizvode muzički instrumenti je mnogo bogatiji od opsega koji ima ljudski govor. Na slici 2.5 može se videti opseg frekvencija i pritiska zvuka govora, muzike i osjetljivosti ljudskog uva. Donji prag je prag čujnosti, a gornji prag je prag bola.



Slika 2.5: Opseg frekvencija i pritiska zvuka koji je potreban da bi ga detektovalo ljudsko uvo [26].

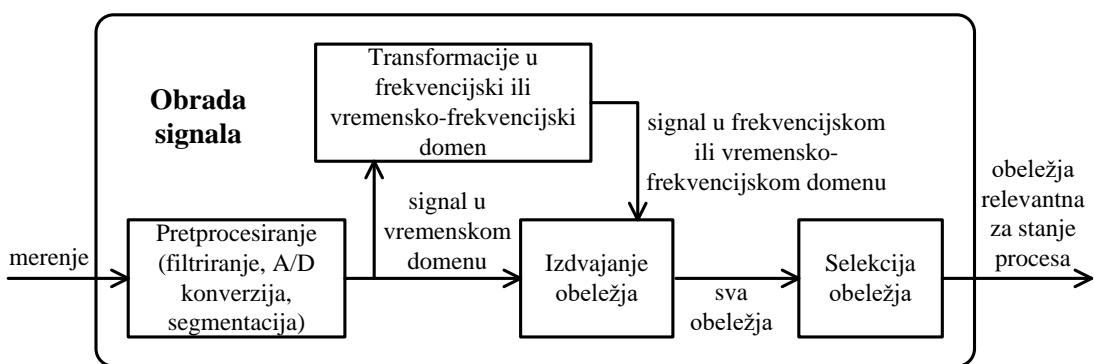
2.2 Obrada i analiza zvučnog signala

Mehaničke strukture svojim vibracijama proizvode zvučni talas, tako da je intuitivno jasno da bi snimanjem akustičkog signala moglo dosta toga da se zaključi o prirodi vibracije strukture koja ga je proizvela. Samim tim, analiza zvučnog signala je korisna u raznim oblastima istraživanja: od analize govora, detekcije govornika, analize i sinteze muzičkih signala, do procene stanja mašina i detekcije otkaza.

Snimanjem zvučnog signala u okolini neke mašine dobija se jako velika količina informacija o samoj mašini, njenom ponašanju, stanju, ali i o okolnim izvorima zvuka. Da bi se te informacije izvukle iz snimljenog signala neophodno je izvršiti obradu signala i izdvojiti relevantne informacije u vidu obeležja [42]. Ove informacije se dobijaju kroz sistem obrade signala koji se sastoji iz koraka prikazanih na slici 2.6.

Prilikom obrade signala prvi korak predstavlja preprocesiranje koje se odnosi na A/D konverziju, čišćenje podataka, filtriranje, segmentaciju i bilo koju drugu operaciju koja će od napravljenog zvučnog snimka kreirati podatke koji su pogodni za dalju obradu. Posle preprocesiranja dobijaju se digitalni podaci u vremenskom domenu. Oni mogu da se koriste za dalju analizu u toj formi ili da se vrši njihova transformacija u frekvenčijski ili neki drugi domen. Finalni korak je izvlačenje informacija (obeležja) iz tako dobijenih podataka.

U zavisnosti od vrste mašine i vrste problema koji se detektuje na datoj mašini, postoje različiti algoritmi koji mogu da se koriste za analizu signala i različita informativna obeležja koja mogu da se izdvoje. Zbog široke primenjivosti zvučnog signala ne postoji objektivno najbolji sled koraka za izdvajanje najinformativnijih podataka. Zato će u ovom delu disertacije biti opisani najčešće korišćeni algoritmi i najčešće izdvojene informacije za problematiku detekcije stanja kod rotacionih aktuatora na bazi analize zvučnog signala.



Slika 2.6: Šematski prikaz procesa obrade signala

Tabela 2.2: Najčešće korišćena obeležja signala x u vremenskom domenu.

Opis	Analogni signal	Digitalni signal
Srednja vrednost	$\bar{x} = \frac{1}{T} \int_0^T x(t) dt$	$\bar{x} = \frac{1}{N} \sum_{n=1}^N x(n)$
Efektivna vrednost	$x_{rms} = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt}$	$x_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)}$
C faktor	$C = \frac{x_{max}}{x_{rms}}$	$C = \frac{x_{max}}{x_{rms}}$
Varijansa	$\sigma^2 = \frac{1}{T} \int_0^T (x(t) - \bar{x})^2 dt$	$\sigma^2 = \frac{1}{N-1} \sum_{n=1}^N (x(n) - \bar{x})^2$
Uvrtanje	$x_{skew} = \frac{1}{\sigma^3 T} \int_0^T (x(t) - \bar{x})^3 dt$	$x_{skew} = \frac{1}{\sigma^3 N} \sum_{n=1}^N (x(n) - \bar{x})^3$
Kurtosis	$x_{kurt} = \frac{1}{\sigma^4 T} \int_0^T (x(t) - \bar{x})^4 dt$	$x_{kurt} = \frac{1}{\sigma^4 N} \sum_{n=1}^N (x(n) - \bar{x})^4$

2.2.1 Vremenski domen

Vremenski domen podrazumeva analizu promene vrednosti signala u vremenu. U zavisnosti od toga da li je snimak analogni ili digitalni vreme je definisano kao bilo koji broj iz skupa realnih brojeva (za kontinualne signale $x(t), t \in \mathbb{R}$) ili kao skup celobrojnih vrednosti (za diskretne signale $x(n), n \in \mathbb{N}$). Ovo je osnovni vid analize signala jer ne zahteva nikakvu dodatnu transformaciju, a neretko se promene na mašini mogu detektovati čistim vizuelnim posmatranjem izgleda signala u vremenu.

Vremenski parametri signala

Istraživanja su pokazala da bazičnim manipulacijama signala u vremenskom domenu mogu da se dobiju parametri koji ukazuju na promenu načina ponašanja mašina. Osnovni parametri kod kojih to može da se primeti su promena srednje vrednosti, efektivne vrednosti, amplitude signala ili odnosa nekih od ovih veličina [43]. U gornjem delu tabele 2.2 pokazani standardni parametri koji se u literaturi koriste kao inicijalna indikacija nekih promena u signalu, kao i način računanja tih parametara na vremenskom intervalu trajanja T sekundi za analogne signale i dužine N odbiraka za digitalne signale.

Osim ovih standardnih parametara zaključeno je da oblik statističke raspodele signala može da bude izuzetno informativan kada se posmatraju promene koje ukazuju na stanje mašine [44]. Naime, promena stanja ili pojava otkaza može da prouzrokuje kratkotrajne impulse koji ne utiču mnogo na standardne vremenske parametre, ali mogu značajno da promene oblik statističke raspodele signala [45]. Možda najinformativniji statistički parametri se odnose na centralne momente funkcije raspodele: uvrtanje (treći centralni mo-

ment) i kurtosis (četvrti centralni moment). Uvrtanje meri simetriju raspodele oko srednje vrednosti, dok kurtosis predstavlja meru oštine pika raspodele. Pozitivno uvrтанje, x_{skew} , generalno ukazuje na pomeranje raspodele desno od srednje vrednosti, dok negativno uvrтанje ukazuje na pomeranje na levo. Sa druge strane, velika vrednost kurtosisa, x_{kurt} , se odnosi na oštar pik raspodele, dok mala vrednost ukazuje na suštinski ravnu karakteristiku. Uticaj ovih parametara, koji se računaju na način prikazan u donjem delu tabele 2.2, u detekciji stanja je više puta potvrđen u literaturi [44] i često se koristi za inicijalnu analizu prilikom detekcije promene stanja ili pojava otkaza na mašini.

Hilbertova transformacija

Hilbertova transformacija je uvedena 1905. godine i od tada je postala nezamenjiv alat u harmonijskoj analizi, pa samim tim i u oblastima koji se bave obradom signala. Hilbertova transformacija signala $x(t)$ se definiše kao [46]

$$x_h(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau, \quad (2.5)$$

i u kontekstu obrade signala koristi se za dobijanje analitičke prezentacije signala

$$x_a(t) = x(t) + jx_h(t), \quad (2.6)$$

gde je $x_a(t)$ analitički signal.

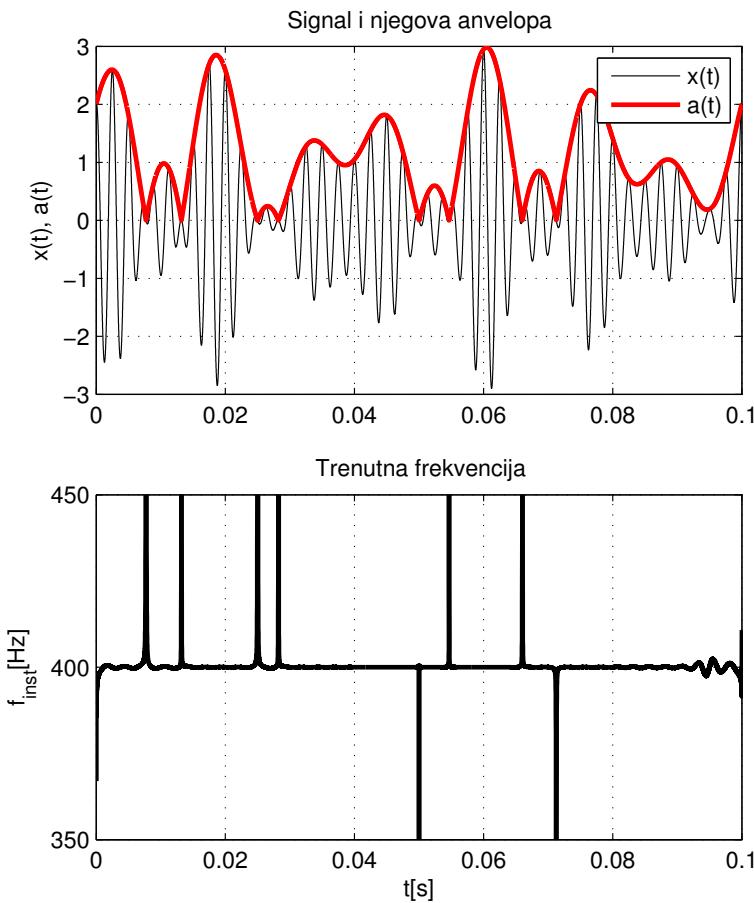
Analitički signal je kompleksan signal koji ima tu osobinu da su mu spektralne komponente na negativnim frekvencijama jednake nuli, a na pozitivnim jednake spektru signala $x(t)$. Kao kompleksan broj on se može napisati u formi

$$x_a(t) = a(t) e^{j\phi(t)}. \quad (2.7)$$

Predstava analitičkog signala u formi iz jednačine 2.7 je izuzetno značajna jer daje informacije o dva važna parametra signala. Trenutna amplituda (engl. *instantaneous amplitude*) signala $x(t)$ obeležava se kao $a(t)$, a naziva se još i anvelopa signala. Izuzetno često se koristi za detekciju lokalnih obeležja signala i demodulaciju modulisanih sekvenci. Trenutna faza (engl. *instantaneous phase*) je drugi značajni parametar koji se koristi za određivanje trenutne frekvencije (engl. *instantaneous frequency*) kao

$$f_{inst}(t) = \frac{1}{2\pi} \frac{d\phi(t)}{dt}. \quad (2.8)$$

Trenutna frekvencija je u opštem slučaju promenljiva u vremenu, što je samo po sebi



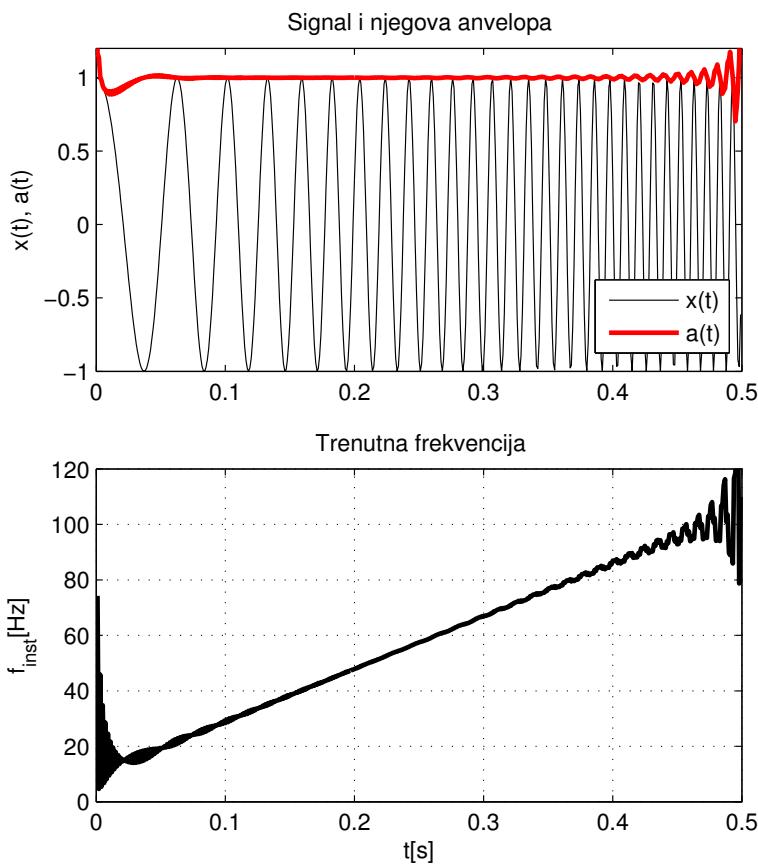
Slika 2.7: Anvelopa (gore) i trenutna frekvencija (dole) stacionarnog signala.

prilično kontraverzan koncept, iz prostog razloga što frekvencija po definiciji predstavlja broj rotacija u jedinici vremena tako da je bilo koja dalja vremenska zavisnost kontraintuitivna [47]. I pored toga, trenutna frekvencija je od velike važnosti za praktičnu primenu kod nestacionarnih signala, jer kod njih dekompozicija na jednostavne sinusoidalne komponente nije dovoljno informativna.

Primer 1: Izgled anvelope i trenutne frekvencije dobijene Hilbertovom transformacijom za signal koji se sastoji od nekoliko prostoperiodičnih komponenti

$$x(t) = (1 + \cos(2\pi \cdot 50t) + \sin(2\pi \cdot 70t)) \cdot \cos(2\pi \cdot 400t) \quad (2.9)$$

može se videti na slici 2.7. S obzirom da je u pitanju stacionaran signal sa uskim spektrom, anvelopa na slici 2.7 (gore) ga potpuno opisuje, a trenutna frekvencija sa slike 2.7 (dole) ima vrednost prosečne frekvencije signala, što je 400 Hz. Pikovi koji se vide na ovom grafiku nastaju u trenucima naglih promena vrednosti anvelope, zbog diferenciranja faze, i nisu informativni za tumačenje karakteristika signala. ▲



Slika 2.8: Anvelopa (gore) i trenutna frekvencija (dole) nestacionarnog signala.

Primer 2: U slučaju nestacionarnih signala trenutna frekvencija prestaje da bude konstantna vrednost. Na slici 2.8 prikazano je ponašanje envelope i trenutne frekvencije za signal koji se sastoji od jedne prostoperiodične komponente čija se frekvencija menja u vremenu. U trenutku $t = 0$ s ona iznosi 10 Hz, pa postepeno raste sve do trenutka $t = 0.5$ s kada iznosi iznosi 100 Hz. Ovaj primer upravo ukazuje na primenljivost trenutne frekvencije, s obzirom da je ona uspešno u svakom trenutku detektovala dinamiku prostoperiodične komponente, a Furijeova analiza razlaganja na harmonike to ne bi uspela. Takođe, čak i ako su u pitanju realni nestacionarni signali sa više komponenti, trenutna frekvencija često ukazuje na neki fizički fenomen koji je opisan tim signalom ▲

2.2.2 Frekvencijski domen

Često je prilikom izvlačenja korisnih podataka iz signala izuzetno informativno poznавanje frekvencijskih komponenti koje su u tom signalu izražene. Ovo je posebno značajno kod signala zvuka i vibracije, a sama činjenica da ljudsko uvo funkcioniše kao neka vrsta frekvencijskog analizatora govori u prilog ovoj tvrdnjji. Da bi se analiza fre-

kvencijskog sadržaja signala mogla izvršiti potrebno je signal iz vremenskog prebaciti u frekvencijski domen, a osnovni alat pomoću kojeg to može da se uradi je Furijeova transformacija.

Furijeova transformacija

Još od 1822. godine, kada je Baron Žan-Baptist-Josef Furije u svojoj knjizi *Analitička teorija toplove* [48] uveo transformaciju kako bi modelovao način na koji se toplota kreće u okolini materijala, ona je postala nezamenjiv alat u gotovo svim naučnim oblastima. Furijeova transformacija se koristi u analizi zvuka, toplove, svetlosti, cena deonica na berzi, astronomiji, medicini, hemiji, za kompresiju podataka, analizu slika, . . . Svet kakav pozajemo ne bi bio isti bez ove matematičke ideje, a lord Kelvin je svakako bio u pravu kada je 1867. godine napisao da „Furijeova teorema nije samo jedan od najlepših rezultata moderne analize, već se može reći da prestavlja nezamenjiv alat za rešavanje skoro svakog skrivenog problema u modernoj fizici” [49].

Furijeova transformacija je proširenje Furijeovog reda koji predstavlja osnovu harmonijske analize uvevši jednostavnu ideju da se periodičan signal $x(t)$ može predstaviti kao beskonačna suma kompleksnih sinusoida

$$x(t) = \sum_{n=-\infty}^{\infty} a_n e^{j2\pi n f_0 t}, \quad (2.10)$$

gde je f_0 osnovna frekvencija periodičnog signala $x(t)$, a_n kompleksan broj koji predstavlja n -ti koeficijent Furijeovog reda i računa se kao rezultat integrala po periodi $T = 1/f_0$

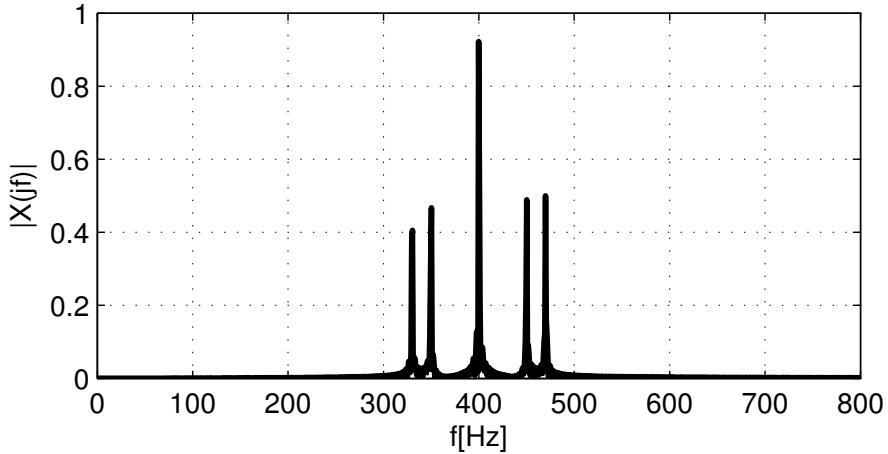
$$a_n = \frac{1}{T} \int_T x(t) e^{-j2\pi n f_0 t} dt. \quad (2.11)$$

Dokaz ove prepostavke je izneo Dirihle, a uslovi pod kojima se signal može razviti u Furijeov red se nazivaju Dirihleovi uslovi.

Furijeova transformacija predstavlja proširenje ideje Furijeovih redova na aperiodične signale. Signal sa ograničenom energijom, $x(t)$, može da se predstavi Furijeovom transformacijom $X(jf)$ kao

$$X(jf) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi f t} dt, \quad (2.12)$$

gde f predstavlja frekvencijsku osu u jedinici [Hz]. To znači da se signal $x(t)$ može dekomponovati u familiju harmonika $e^{j2\pi f t}$. $X(jf)$ je nezavisno od vremena i predstavlja frekvencijsku kompoziciju signala za koji se prepostavlja da je stacionaran, tako da se njegove statistike ne menjaju s vremenom. S obzirom da Furijeova transformacija pred-



Slika 2.9: Amplitudski spektar signala iz primera 1.

stavlja signal u kompleksnom domenu, ona se može napisati kao

$$X(jf) = |X(jf)| e^{j\arg\{X(jf)\}}. \quad (2.13)$$

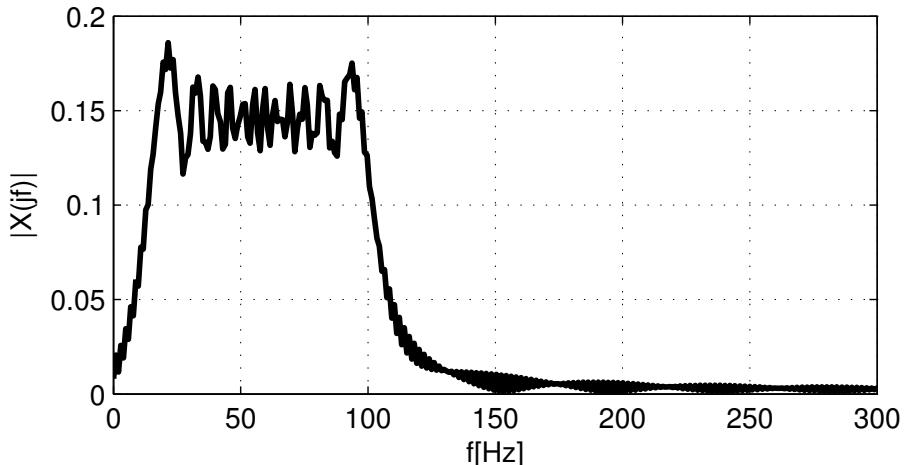
Ovde $|X(jf)|$ predstavlja amplitudski spektar signala $x(t)$, a $\arg\{X(jf)\}$ predstavlja faznu frekvenčnu karakteristiku.

Primer 3: Signal iz primera 1, dat jednačinom 2.9, se sastoji iz nekoliko prostoperiodičnih komponenti; naime, to je signal sa komponentama na 0 Hz, 50 Hz i 70 Hz modulisani sa kosinusoidom od 400 Hz. Ove informacije nisu očigledne iz predstave signala u vremenskom domenu i njegove envelope na slici 2.7, međutim posmatranjem amplitudsko frekvenčne karakteristike signala na slici 2.9 svaka od ovih komponenti je jasno vidljiva. ▲

Jednačina 2.12 predstavlja analitičku relaciju signala $x(t)$. Povratak iz frekvenčnog domena u vremenski se obavlja sintetičkom relacijom

$$x(t) = \int_{-\infty}^{\infty} X(jf) e^{j2\pi ft} df. \quad (2.14)$$

Furijeova transformacija je dominantni alat za analizu signala zbog njene jednostavnosti i informativnosti, međutim postoje neke krucijalne restrikcije u njenom korišćenju. Naime, poželjno je da signal koji se posmatra bude stacionaran i da opisuje linearan proces. U suprotnom Furijeova transformacija signala može da sadrži komponente koje nemaju mnogo fizičkog smisla. Nelinearni fenomeni u signalu su direktna posledica nelinearnih diferencijalnih jednačina koje opisuju mereni proces i manifestuju se preko harmonijske distorzije, odnosno dodavanjem cikličnih komponenti na višim harmonicima osnovne



Slika 2.10: Amplitudski spektar signala iz primera 2.

učestanosti [70]. Sa druge strane, stacionarnost se odnosi na vremensku nepromenljivost signala.

Primer 4: Signal iz primera 2 je izrazito nestacionaran, iako se u svakom trenutku sastoji samo od jedne prostoperiodične komponente. Furijeova transformacija tog signala može se videti na slici 2.10. Ono što je očigledno iz ove slike je da se javljaju sve komponente na frekvencijama između 10 Hz i 100 Hz, međutim nije jasno iz ovakve prezentacije signala da li se sve ove komponente javljaju istovremeno ili postepeno. ▲

Furijeova transformacija je uspešno primenjivana za procesiranje akustičkih signala mašina i pokazano je da su amplitude u frekvencijskom domenu zavisne od stanja mašina. Problem je što je snimak mašine esencijalno nestacionaran, tako da frekvencijska kompozicija u formi Furijeove transformacije predstavlja usrednjeno frekvencijsko ponašanje u toku trajanja signala. Kao rezultat Furijeova transformacija ne može adekvatno da predstavi tranzijentalne periode signala [51]. Ovaj nedostatak može donekle da se ublaži tako što se kod nestacionarnog signala posmatra Furijeova transformacija na kratkom vremenskom periodu na kome se stacionarnost može prepostaviti.

Prilikom analize signala u frekvencijskom domenu, umesto čiste Furijeove transformacije nekad se koristi i informacija o spektralnoj gustini snage signala. Ona opisuje kako je snaga nekog signala raspoređena po frekvencijama. Spektralna gustina snage signala $x(t)$ se definiše kao

$$S_{xx}(f) = \int_{-\infty}^{\infty} E\{x(t)x(t-\tau)\}e^{-j2\pi f\tau}d\tau, \quad (2.15)$$

gde operater $E\{\cdot\}$ predstavlja matematičko očekivanje, a $E\{x(t)x(t-\tau)\}$ je autokorelaciona funkcija signala $x(t)$. Samim tim, spektralna gustina snage signala predstavlja Furijeovu transformaciju njegove autokorelaceione funkcije. S obzirom da se najčešće vrši

manipulacija diskretnim signalima $x(n)$, u tom slučaju spektralna gustina snage za signal ograničen sa N odbiraka može da se aproksimira periodogramom

$$\hat{S}_{xx}(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi fn} \right|^2. \quad (2.16)$$

Kepstralna analiza

U prvom pominjanju kepstralne analize ona je definisana kao „spektar snage logaritma spektra snage” [52]. Po definiciji kompleksni kepstrum je inverzna Furijeova transformacija prirodnog logaritma Furijeove transformacije signala $x(t)$

$$C_x(\tau) = \mathcal{F}^{-1}(\ln(X(jf))). \quad (2.17)$$

Slično može da se definiše i kepstralna snaga kao

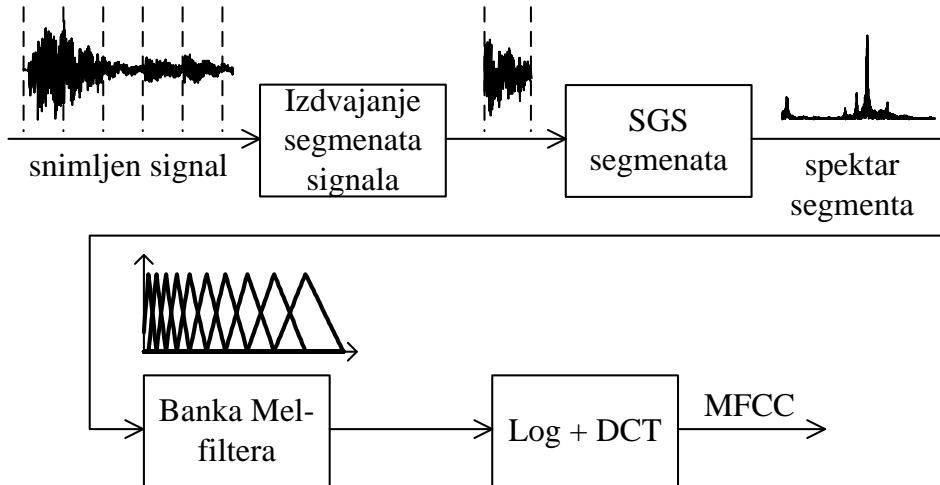
$$C_{px}(\tau) = \left| \mathcal{F}^{-1}(\ln(|X(jf)|^2)) \right|^2. \quad (2.18)$$

Reč kepstrum nastaje invertovanjem prva četiri slova reči spektrum. Slično, promenljiva τ kod izraza $C_x(\tau)$ se naziva kvefrencija. Kepstrum nosi informaciju o stopi promene signala u različitim spektralnim opsezima. Originalno je uveden za karakterizaciju seizmičkih eha koji nastaju kao rezultat zemljotresa ili eksplozija bombi, a često se koristi i za utvrđivanje osnovne frekvencije ljudskog govora.

Naučnici su postali svesni mogućnosti primene kepstralne analize u praćenju stanja rotirajućih mašina još 70ih godina [53]. Naime, lokalna oštećenja u rotirajućim elemenima uzrokuju impulsnu modulaciju signala zvuka koji proizvodi mašina i kao rezultat se dobija velika količina ekvidistantnih frekvencijskih pikova. Dobar deo tih pikova je vidljiv samo na logaritamskoj skali amplitude spektra, tako da je kepstralna analiza idealan način da se ovakve promene detektuju.

Mel-frekvencijski kepstralni koeficijenti (engl. *Mel-Frequency Cepstral Coefficients*, MFCC) su informacije dobijene iz kratkovremenskog spektra snage signala korišćenjem linearne kosinusne transformacije i logaritma spektra na Mel-skaliranim frekvencijama. Način izdvajanja ovih obeležja je šematski prikazan na slici 2.11. Procedura je prilično računarski jednostavna za implementaciju i sastoji se od nekoliko koraka.

Prvo je potrebno podeliti signal na kraće segmente (frejmove). Dužina ovih segmenta zavisi od samog signala koji se posmatra, ali se načelno usvaja pravilo da deo signala obuhvaćenog frejmom treba da bude približno stacionaran. Dakle, što se brže signal me-



Slika 2.11: Blok dijagram za izračunavanje Mel-kestralnih koeficijenata.

nja u vremenu, to je kraći segment koji se izdvaja. Za potrebe analize govornog signala, na primer, dužina frejmova je uglavnom 20-40 ms.

Sledeći korak se odnosi na računanje spektralne gustine snage izdvojenog segmenta i primenu banke Mel-skaliranih trougaonih filtara. Mel-skaliranje frekvencija se odnosi na nelinearni vid skaliranja koji ima mnogo veću rezoluciju na niskim frekvencijama nego na visokim. Na ovaj način se modeluje mehanizam na koji ljudi razaznaju zvukove, jer je ustanovljeno da mnogo veću osjetljivost imaju na promene tona na niskim frekvencijama nego na visokim. Dobijanje Mel-skale iz obične frekvencije se vrši preko logaritamskog preslikavanja

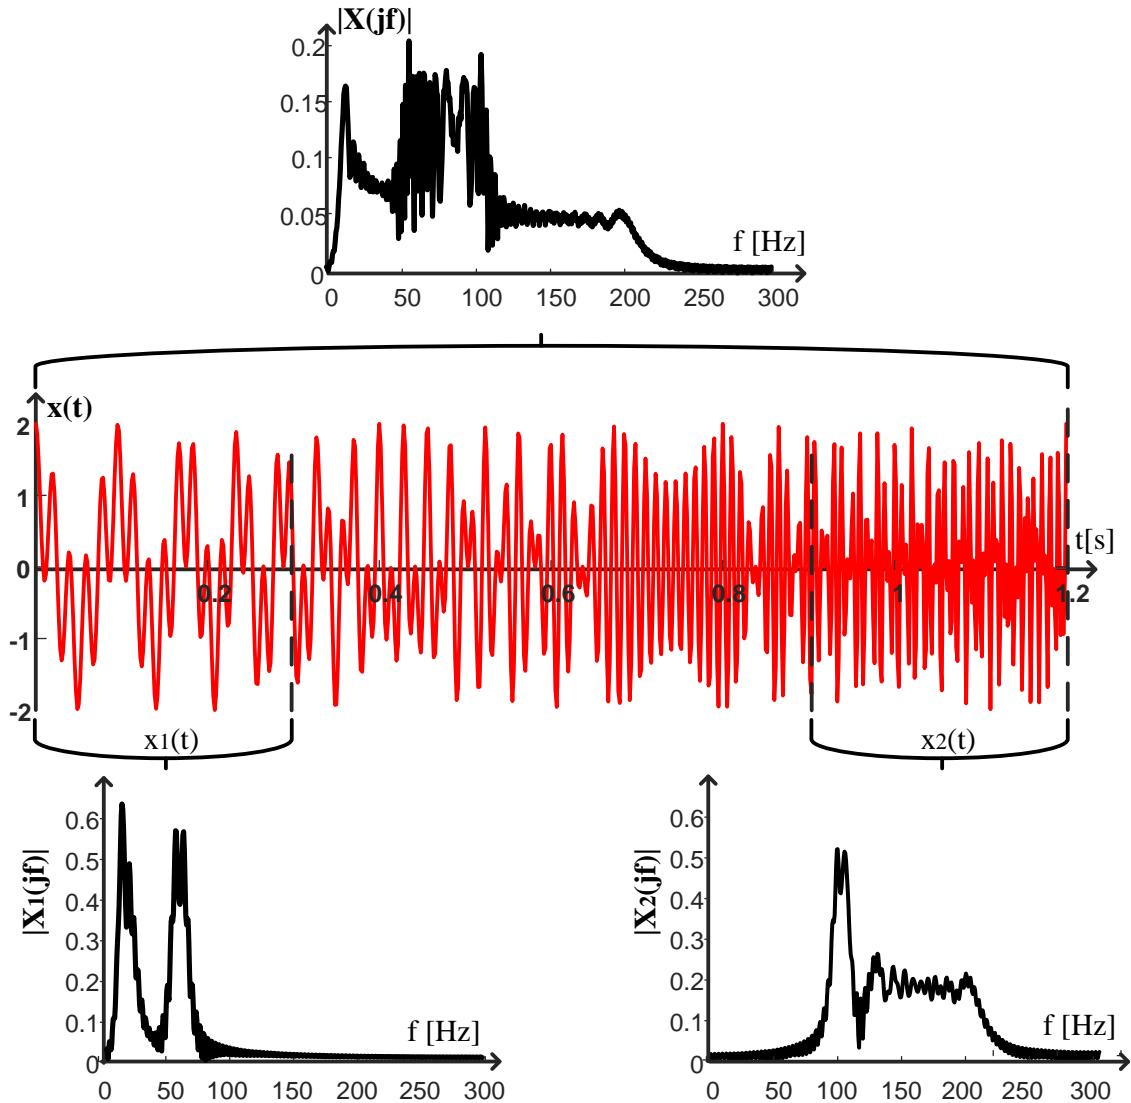
$$M(f) = 1125 \ln\left(1 + \frac{f}{700}\right). \quad (2.19)$$

Posle filtriranja Mel-frekvencijskim trouganim filtrima potrebno je izračunati prirodnji logaritam tako filtriranih signala i primeniti diskretnu kosinusnu transformaciju (DCT) [54] radi dekorelacije energije filtriranih signala. Najzad, obeležja koja se zadržavaju su koeficijenti diskretnе kosinusne transformacije.

2.2.3 Vremensko-frekvencijski prikaz

Analiza signala u vremenskom ili frekvencijskom domenu se najčešće koristi ako je posmatrani signal stacionaran, odnosno ako se njegove karakteristike ne menjaju vremenom. U suprotnom informacije koje se dobijaju ovim analizama su obmanjujuće i mogu dovesti do pogrešnih zaključaka. Jedan takav primer je prikazan na slici 2.12. Signal se u početku sastoji od dve prostoperiodične komponente na niskim frekvencijama. Kako vreme protiče tako se te dve komponente pomeraju ka višim frekvencijama, tako da signal

nije stacionaran. Ako bismo posmatrali spektar početnog dela signala, $|X_1(jf)|$, i krajnjeg dela signala, $|X_2(jf)|$, Oni se značajno razlikuju jedan u odnosu na drugi. Sa druge strane, posmatrajući spektar celokupnog signala, $|X(jf)|$, dobija se uvid u usrednjeno ponašanje signala $x(t)$. Na taj način bi se moglo pogrešno zaključiti da su sve spektralne komponente stalno prisutne, što svakako nije slučaj.



Slika 2.12: Nestacionaran signal u vremenskom (crveno) i frekvencijskom domenu (crno).

U praksi je pojava stacionarnih signala više izuzetak nego pravilo, posebno ako se radi o signalima zvuka. Naime, ljudski govor i muzika su klasični primeri izuzetno nestacionarnih signala, a zvukovi mašina takođe imaju različite frekvencijske komponente u zavisnosti od promene režima rada ili istrošenosti. Osnovni uzrok nestacionarnosti zvučnog signala mašina je činjenica da sadržaj određenih frekvencijskih komponenti zavisi od fizičkih parametara uređaja koji mogu da se menjaju vremenom [46]. Prikaz vremensko-

frekvencijske raspodele signala je najčešće korišćen način za posmatranje spektara nestacionarnih signala.

Oblast analize signala u vremensko-frekvencijskom domenu je svoje začetke imala u četrdesetim godinama 20. veka i direktno je inspirisana dostignućima iz kvantne mehanike [55]. Naime, uočeno je mnogo paralela između vremena i frekvencije u obradi signala i pojmove brzine i pozicije u kvantnoj mehanici. Tako Hajzenbergov princip neodređenosti, koji kaže da proizvod standardne devijacije pozicije i standardne devijacije brzine čestice mora da bude veći od polovine Plankove konstante [56], se može prevesti u oblast obrade signala. Kod vremensko-frekvencijske analize princip neodređenosti se nekad zove i Hajzenberg-Gaborova granica i može se predstaviti kao

$$\Delta t \Delta \omega \geq c, \quad (2.20)$$

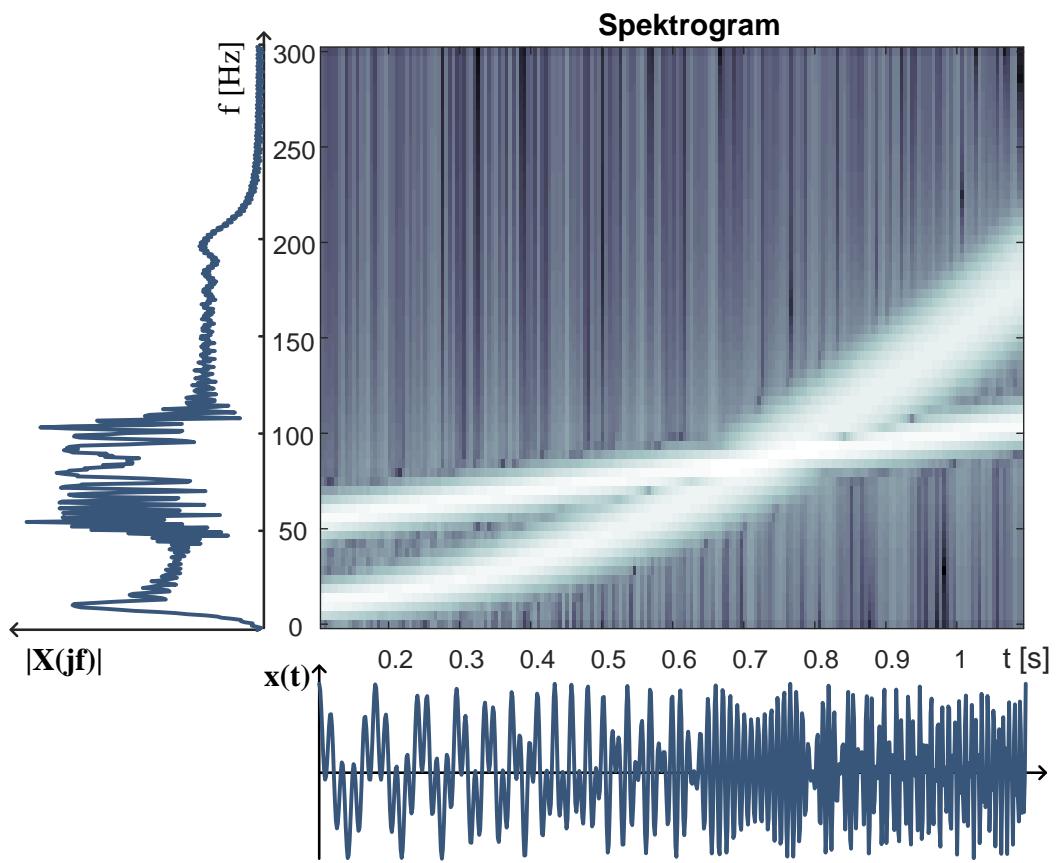
gde je Δt vreme trajanja signala, $\Delta \omega$ frekvencijski opseg koji signal obuhvata, a c konstanta koja zavisi od definicije trajanja i frekvencijskog opsega koju usvojimo. Ako ih definišemo kao intervale u kojima je signal različit od nule, onda važi $\Delta t \Delta \omega \rightarrow \infty$. Sa druge strane, ako ih definišemo kao normalizovane druge momente kvadrata amplitude [57], onda važi $c = 1/2$.

Osnovna posledica principa neodređenosti kod vremensko-frekvencijske analize je osobina da signali koji imaju kratko trajanje u vremenskom domenu imaju jako širok spektar, i obrnuto. U praktičnom smislu to znači da je nemoguće istovremeno precizno lokalizovati signal u vremenskom i frekvencijskom domenu, odnosno nemoguće je ostvariti veliku vremensku i frekvencijsku rezoluciju istovremeno.

Spektrogram

Najstarija metoda za dvodimenzionalnu, vremensko-frekvencijsku, predstavu signala je kratkovremenska Furijeova transformacija (engl. *Short-Time Fourier Transform*, STFT). Prvi put je upotrebljena od strane Gabora 1946. godine u obradi govora [58]. Ideja je da se posmatra spektar signala u nekom trenutku tako što se uzme signal u okolini tog vremenskog trenutka i izračuna se njegova Furijeova transformacija. Ovo se realizuje tako što se signal $x(t)$ pomnoži prozorskom funkcijom i izračuna Furijeova transformacija tog proizvoda. Posle toga se prozor pomera duž vremenske ose i račun se ponavlja sve dok se ne dođe do kraja signala. Najčešće se ova promena spektra skicira kao funkcija vremena. Kratkovremenska Furijeova transformacija se računa kao

$$X_{STFT}(t, f) = \int_{-\infty}^{\infty} x(\tau)w(\tau - t)e^{-j2\pi f\tau}d\tau, \quad (2.21)$$

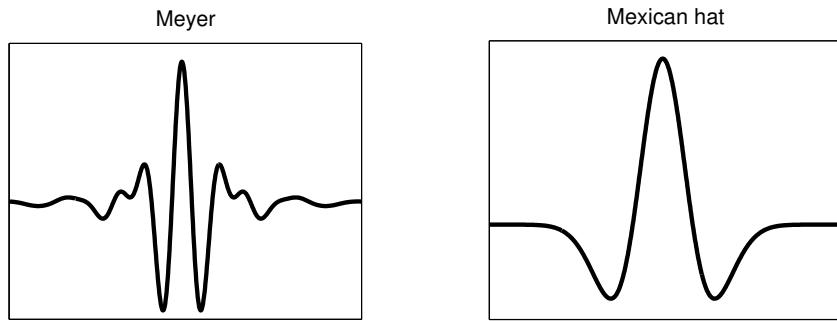


Slika 2.13: Spektrogram signala koji se sastoji od dve promenljive prostoperiodične komponente. Na apscisi je prikazan i izgled signala u vremenskom domenu, dok je na ordinati izgled signala u frekvencijskom domenu.

gde je $w(t)$ prozorska funkcija centrirana oko nule. Ona može da bude različitog oblika, a oblik utiče na relativne težine koje su dodeljene određenim delovima signala. Tako, na primer, prozor koji daje znatno veću težinu intervalu u okolini posmatranog trenutka nagašava lokalne osobine signala. Najčešće korišćene prozorske funkcije su pravougaona, Hanova ili Gausovska. U posebnom slučaju kada se koristi Gausovska funkcija, STFT se naziva i Gaborova transformacija. Za vizuelnu prezentaciju promene spektra signala u vremenu se najčešće koristi spektrogram i on se računa preko kratkovremenske Furijeove transformacije kao

$$S(t, f) = |X_{STFT}(t, f)|^2. \quad (2.22)$$

Spektrogram se može protumačiti kao mera energije signala sadržana u određenom vremensko-frekvencijskom opsegu. Najčešći način prikazivanja trodimenzionalnog spektrograma je pomoću dvodimenzione slike u boji. Dve ose na toj slici odgovaraju vremenu i frekvenciji, a boja rasprostranjena po vremensko-frekvencijskom području odgovara



Slika 2.14: Najčešće korišćeni talasići.

amplitudi. Loša strana spektrograma je njegova fiksna rezolucija, odnosno ograničena preciznost. Naime, širina prozora direktno određuje vremensku i frekvencijsku rezoluciju. Ako je prozorska funkcija široka ona daje dobru frekvencijsku rezoluciju (lakše je razdvojiti bliske frekvencijske komponente) a lošu vremensku, i obrnuto [59].

Izgled spektrograma signala sa slike 2.12 može se videti na slici 2.13. Iz vremensko-frekvencijskog prikaza jasno se vide dve prostoperiodične komponente koje se pomeraju sa nižih na više učestanosti. U trenutku $t = 0.7$ s te dve komponente se na kratko preklapaju, da bi posle toga nastavile da se udaljavaju.

Wavelet transformacija

Za razliku od spektrograma koji daje dvodimenzionalnu prezentaciju signala, ali sa fiksnom rezolucijom, *Wavelet* transformacija (WT) omogućava adaptiranje vremenske rezolucije za analizu lokalnih frekvencijskih komponenti signala. Dakle, moguća je lokalizacija istovremeno u vremenskom i frekvencijskom domenu. Sama transformacija je slična Furijeovoj transformaciji, međutim umesto aproksimacije datog signala trigonometrijskim funkcijama (sinusom i kosinusom), *Wavelet* transformacija uzima talasiće (engl. *wavelets*) ograničenog trajanja [60].

Bira se matični talasić $\psi(t)$ sa ograničenim trajanjem i nultom srednjom vrednošću koji je kvadratno-integrabilan. Od matičnog talasića se prave novi talasići $\psi_{a,b}(t)$ koji su skalirani sa $a > 0 \in \mathbb{R}$ i translirani za $b \in \mathbb{R}$ u odnosu na $\psi(t)$ [51]

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right). \quad (2.23)$$

Primeri najpopularnijih talasića koji se koriste mogu se videti na slici 2.14.

Wavelet transformacija signala $x(t)$ se dobija kao

$$X_{WT}(a, b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt, \quad (2.24)$$

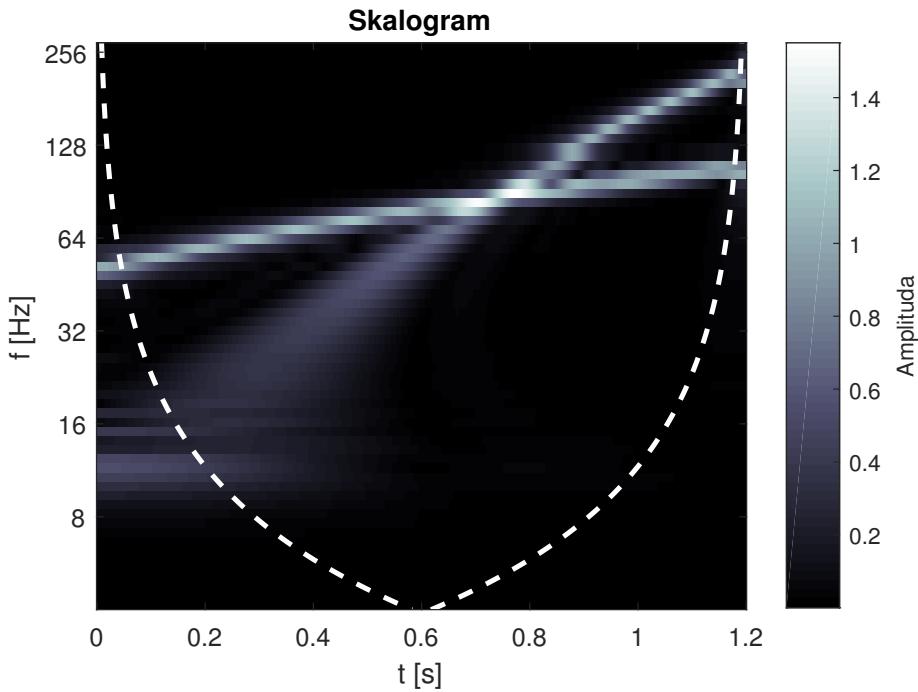
i predstavlja funkciju dve promenljive: skala faktora a i translacionog parametra b . S obzirom da nije računarski izvodljivo odrediti *Wavelet* transformaciju za sve realne vrednosti parametara a i b , često se umesto kontinualne WT iz jednačine 2.24 koristi diskretna WT sa parametrima $(a^m, nb); n, m \in \mathbb{Z}$ za neke realne vrednosti $a > 1, b > 0$.

Wavelet transformacija je imala jako puno primena u zadnjih dve decenije za analizu nestacionarnih procesa. Primarno se koristi kao matematički alat za analizu podataka u vremenskom i frekvencijskom domenu, a našla je primenu u oblastima kao što su obrada signala, prepoznavanje slika i identifikacija različitih aspekata sistema [61]. U detekciji stanja mašina pokazala se kao veoma informativna ne samo zbog toga što vrši lokalizaciju u vremenu i frekvenciji, već i zato što se može koristiti kao filter koji bi razdvojio periodične od neperiodičnih komponenti signala, odnosno za izdvajanje prelaznih delova signala koji mogu da kriju informacije o vrsti otkaza [43], a uspešno je primenjena na analizi rada mlinja koristeći signale vibracije [62]. Problem kod *Wavelet* transformacije je u tome što su obeležja koja se izdvajaju iz nje izuzetno osjetljiva na kašnjenje, pa isti signal koji je malo zakašnjen dobija dosta izmenjena WT obeležja. Takođe, kontinualna WT je izuzetno računski zahtevna, a diskretna WT nema dobru rezoluciju na visokofrekvencijskim opsezima, tako da za tu vrstu analize nije preporučljiva [63].

Wavelet transformacija se grafički predstavlja pomoću skalograma, na sličan način na koji se kratkovremenska Furijeova transformacija predstavlja preko spektrograma. Primer skalograma na signalu sa slike 2.12 može se videti na slici 2.15. Zbog logaritamskog preslikavanja skala faktora u frekvenciju jasno je da skalogram ima veću frekvencijsku rezoluciju na niskim frekvencijama, ali je zato tu vremenska rezolucija znatno niža. Isprekidana linija predstavlja vremensko-frekvencijsku oblast u kojoj ivični efekti *Wavelet* transformacije dolaze do izražaja.

Wigner-Ville distribucija

Kratkovremenska Furijeova transformacija i *Wavelet* transformacija spadaju u klasu linearnih vremensko-frekvencijskih predstava signala. Spektrogram je, sa druge strane, kvadratna ili bilinearna prezentacija jer predstavlja meru energije signala na određenom vremensko-frekvencijskom domenu. Wigner-Ville distribucija (WVD) je takođe bilinearna transformacija i bazira se na korišćenju autokorelacionih funkcija za računanje spek-



Slika 2.15: *Skalogram signala koji se sastoji od dve promenljive prostoperiodične komponente.*

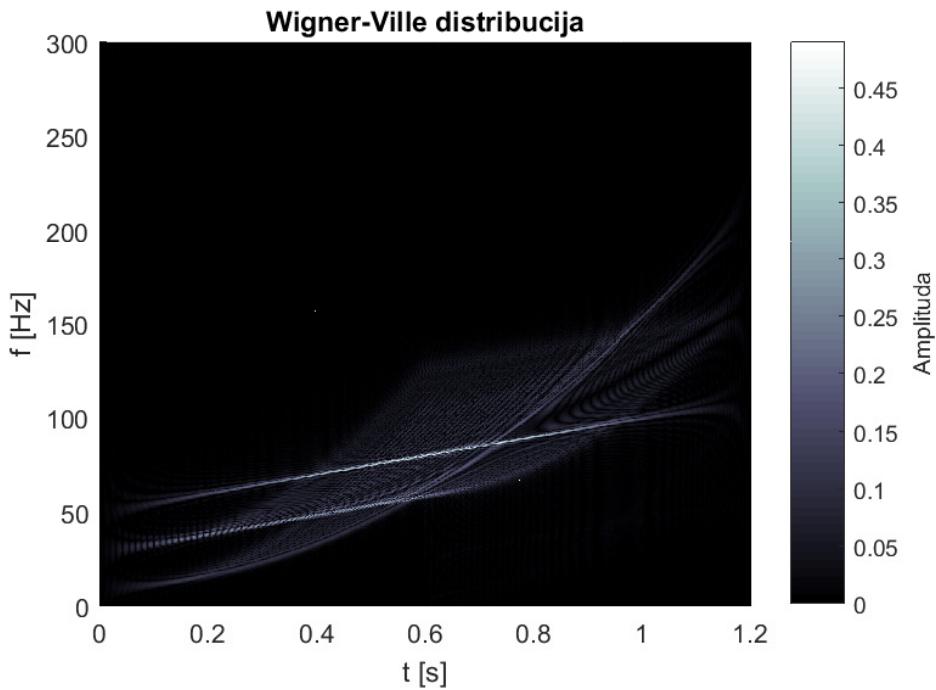
tra snage i definisana je kao

$$X_{WVT}(t, f) = \frac{1}{2\pi} \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau, \quad (2.25)$$

gde $x^*(\cdot)$ predstavlja kompleksno transponovanje signala $x(\cdot)$.

Posmatranjem jednačine 2.25 jasno je se WVD dobija poređenjem signala sa samim sobom, u različitim vremenskim trenucima i frekvencijskim područjima. Ona daje bolju vremensku i frekvencijsku rezoluciju od spektrograma. Takođe, trenutna frekvencija iz 2.8 može da se aproksimira iz ove transformacije kao prvi moment (odnosno centar mase) u frekvenciji, dok grupno kašnjenje može da se odredi kao prvi moment u vremenu. Negativni aspekti WVD uključuju pojavu artefakta u spektru zbog interferencije signala u različitim vremenskim i frekvencijskim delovima, kao i mogućnost pojave negativnih vrednosti spektra koji bi odgovarali negativnoj energiji, što fizički nije moguća pojava [55].

Wigner je uveo ovu raspodelu 1932. [64] u oblasti kvantne mehanike, povezujući talasnu funkciju iz Šreдинgerove jednačine sa raspodelom verovatnoće u faznom prostoru. Ville je 1948. godine proširio njenu primenu na polje obrade signala u vremensko-frekvencijskom domenu [65]. Zbog svojih korena u kvantnoj mehanici ova procedura se ne zove *transformacija*, već *distribucija*, iako to može da ima pogrešne konotacije,



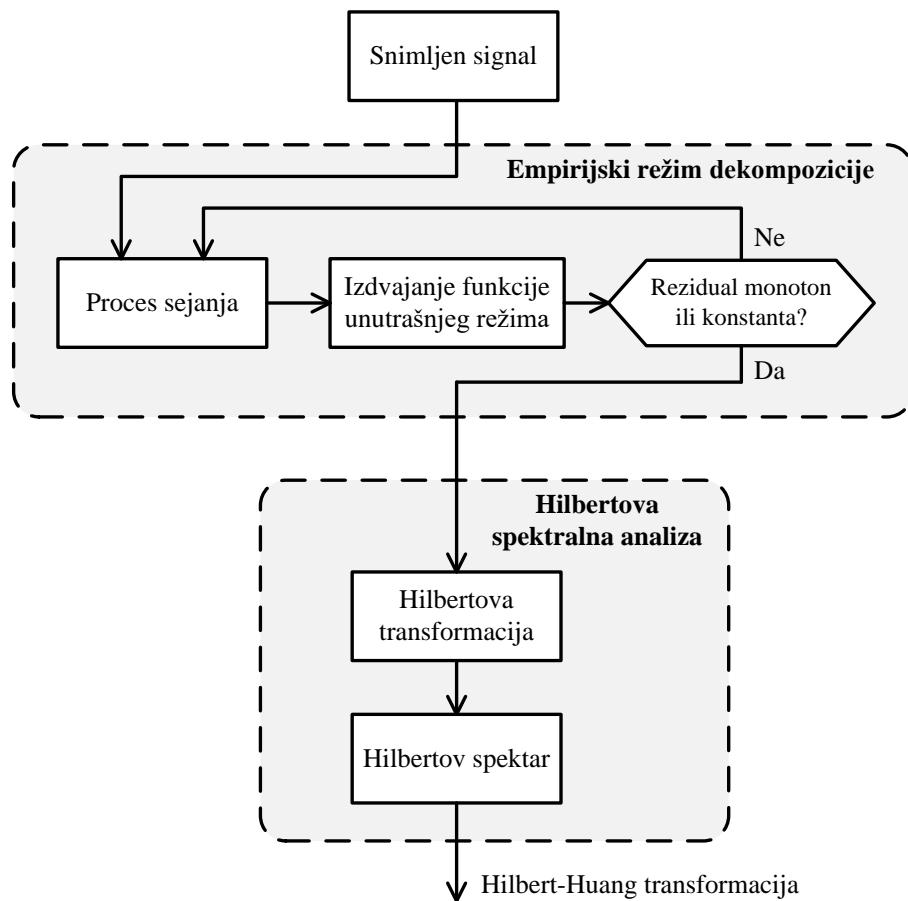
Slika 2.16: *Wigner-Ville distribucija signala koji se sastoji od dve promenljive prostoperiodične komponente.*

s obzirom da se pojam *distribucija* često povezuje sa statističkom distribucijom signala, a to ovde nije slučaj. Devedesetih godina 20. veka je došlo do ekspanzije primene ove transformacije u cilju detekcije otkaza, posebno na primeru rotacionih aktuatora [66, 67]. Najčešće se koristila u cilju analize signala vibracije, međutim u zadnjih nekoliko godina je svoju primenu našla i u opisivanju ponašanja signala zvuka [68, 69].

Primena Wigner-Ville distribucija na signal sa slike 2.12 može se videti na slici 2.16. Na prvi pogled se primećuje da ova transformacija ima najbolju rezoluciju u vremenskom i frekvencijskom domenu, odnosno jasno se vide tačne frekvencije i vremenski trenuci u kojima se javljaju prostoperiodične komponente. Međutim, odmah se uočava i glavni nedostatak ove transformacije, a to je pojava artefakta u vidu dodatnih prostoperiodičnih komponenti koji ne postoje u originalnom signalu.

Hilbert-Huang transformacija

Postoji pregršt standardnih metoda za analizu podataka za koje važi prepostavka o linearnosti i stacionarnosti. Wigner-Ville transformacija i *Wavelet* transformacija se bave obradom nestacionarnih podataka za koje prepostavka o linearnosti važi, dok postoje i neke metode analize vremenskih serija koje se bave obradom stacionarnih podataka za koje ne mora da važi prepostavka o linearnosti. Za obradu nelinearnih i nestacionarnih



Slika 2.17: Blok dijagram za izračunavanje Hilbert-Huang transformacije.

podataka potrebna je adaptivna osnova za predstavu signala, a Hilbert-Huang metoda (HHT) omogućava upravo to. Za razliku od ostalih algoritama pomenutih ovde koji su teorijski dokazani, HHT je i dalje čisto empirijska metoda; međutim, iako je uvedena pre desetak godina već ima jako puno praktičnih primena koji potvrđuju njenu korisnost.

Način određivanja parametara HHT je prilično kompleksan i u ovoj disertaciji će biti samo okvirno opisan. Detaljni proračuni koji se koriste za generisanje ove transformacije mogu se naći u originalnom Huangovom radu [70]. Način računanja HHT prikazan je na slici 2.17 i može se predstaviti preko dva osnovna koraka.

Prvi korak u dobijanju Hilbert-Huang transformacije se naziva empirijski režim dekompozicije (engl. *Empirical Mode Decomposition*, EMD) i predstavlja razdvajanje signala na konačan broj komponenti na sličan način na koji to radi Furijeov red. Umesto dekompozicije na kompleksne sinusoide kao u jednačini 2.10, signal se kod HHT rastavlja na funkcije unutrašnjeg režima (engl. *Intrinsic Mode Functions*, IMF). Da bi funkcija bila okarakterisana kao IMF mora da zadovolji sledeće osobine:

- Broj ekstremuma i broj prolaska kroz nulu moraju da budu isti ili da se razlikuju

maksimalno za jedan.

- Srednja vrednost između anvelope određene maksimumima i anvelope određene minimumima mora da bude jednaka nuli.

Iz ovoga je jasno da funkcije unutrašnjeg režima predstavljaju jednostavno oscilatorno kretanje koje može da ima promenljivu amplitudu i frekvenciju u toku vremena. Takođe, one često imaju konkretno fizičko značenje.

Proces određivanja funkcija unutrašnjeg režima je iterativan i naziva se „procedura sejanja“ (engl. *sifting*) [71]. Ideja je da se od originalnog signala oduzme srednja vrednost pozitivne i negativne envelope. Ako tako dobijen signal zadovoljava uslove za IMF procedura sejanja se završava, usvaja se prva funkcija unutrašnjeg režima, računa se rezidual originalnog signala i IMF komponente i procedura se ponavlja u potrazi za sledećom IMF. U slučaju da signal ne zadovoljava uslove za IMF, procedura sejanja se nastavlja.

Režim empirijske dekompozicije se završava onda kada rezidual postane konstanta ili monotona funkcija. Tako dekomponovan signal se može predstaviti kao

$$x(t) = \sum_{j=1}^n c_j(t) + r_n(t), \quad (2.26)$$

gde $c_j(t)$ predstavljaju IMF komponente, a $r_n(t)$ je rezidual.

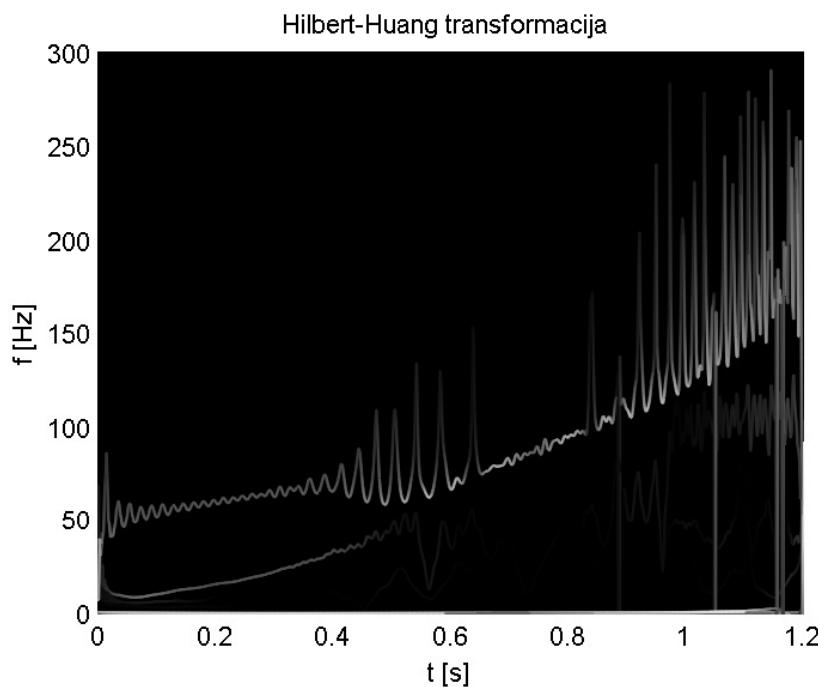
Drugi korak je Hilbertova spektralna analiza (HSA) i ona podrazumeva određivanje Hilbertove transformacije svake IMF komponente kao u jednačini 2.5 i izdvajanje envelope i trenutne frekvencije kao u 2.8. Hilbert-Huangov spektar se dobija kao realni deo sume spektralnog ponašanja Hilbertove transformacije svake od n funkcija unutrašnjeg režima

$$X_{HHT}(t, f) = \operatorname{Re} \sum_{i=1}^n a_i(t) e^{j \int 2\pi f_i(t) dt}, \quad (2.27)$$

gde $a_i(t)$ predstavlja envelopu, a $f_i(t)$ trenutnu frekvenciju i -te IMF.

HHT se sve češće koristi za obradu signala zvuka i vibracija prilikom detekcije napuklina rotora, s obzirom da jeste u pitanju nelinearan i nestacionaran signal [63, 72]. Nedostaci ove transformacije su uzrokovani činjenicom da konvergencija još uvek nije teorijski dokazana, kao i potencijalnom slabom informativnošću IMF komponenti. Naime, u zavisnosti od signala, pojedine IMF komponente mogu ili da imaju previše širok frekvencijski opseg ili da ne budu dovoljno informativne na niskim frekvencijama. Takođe, može da bude teško razdvojiti pojedine komponente čiji je uticaj slabije izražen zato što imaju malu energiju u odnosu na celokupan signal.

Primena HHT na signal sa slike 2.12 može se videti na slici 2.18. Jasno je da, slično



Slika 2.18: *Hilbert-Huang transformacija* signala koji se sastoji od dve promenljive stopoperiodične komponente.

kao Wigner-Ville transformacija, i HHT ima odličnu rezoluciju po vremenu i frekvenciji, ali ima problem da prati promenu različitih komponenti, posebno ako su frekvencijski veoma blizu. Tako se može primetiti da ne samo da je HHT poprilično kontaminirana pikovima, već i dominantno naglašava isključivo komponentu na višim frekvencijama dodeljujući joj izuzetno širok frekvencijski opseg, a zanemaruje onu na nižim.

2.3 Karakterizacija zvučnog signala u industriji

Uređaji za snimanje zvučnog signala postoje odavno, kao i tehnike za njegovu obradu koje su delom opisane u prethodnom poglavlju, ali i pored toga su algoritmi za obradu zvučnog signala sa ciljem primene u prediktivnom održavanju počeli da se koriste tek prethodnih nekoliko decenija, dok je praktična primena ovih signala u industriji je još ređe rasprostranjena. Ovo je verovatno zbog percepcije da je zvuk maštine koji se prostire kroz vazduh često kontaminiran šumom u normalnim industrijskim uslovima. Tek korišćenjem naprednijih tehnika za obradu signala postaje moguće izvući potrebne informacije iz signala zvuka. Razvojem algoritama za detekciju stanja maština koji koriste vibraciju i akustičku emisiju, izuzetno se doprinelo razvoju algoritama za zvučnu dijagnostiku, prvenstveno zbog slične prirode signala koji se koriste. Što se tiče vibracije, njom se meri sličan trend ponašanja kao i kod zvučnog signala, s obzirom da samo vibiranje elemenata proizvodi zvuk. Sa druge strane, akustička emisija koristi u osnovi sličan pristup ali na drugom frekvencijskom opsegu.

Začetak korišćenja akustičkih signala u industriji može se pratiti unazad do kraja šezdesetih godina prošlog veka kada je Weichbrodt detektovao da zvučni signal zaista nosi informaciju o stanju mehaničkih struktura [73]. Sedamdesetih godina prošlog veka Grabec i Leskovar su analizirali zvuk koji emituje proces sečenja aluminijuma [74] i došli su do zaključka da je spektar zvučnog dela signala diskretan, dok je supersonični opseg (koji se kasnije nazvao akustička emisija) kontinualan. Analiziranjem uticaja parametara sečenja na spektar zaključili su da akustička emisija može da se koristi u proceni naoštrenosti alata za sečenje. U sličnom periodu Dyder i Stewart koriste signale vibracije da procene količinu oštećenosti rotirajućih elemenata [75]. Dok je Grabec koristio jednostavnu analizu u frekvencijskom domenu za detekciju naoštrenosti, Dyder primenjuje statističku analizu u vremenskom domenu posmatrajući kurtosis, odnosno četvrti moment.

Osamdesetih godina nastavlja se trend analize vibracionih i akustičkih signala i radi se na kreiranju kompleksnijih algoritama sposobnih za detekciju skrivenih problema. Takata je koristio algoritme za prepoznavanje govora koje je direktno primenio na mašinama, a sve to u cilju kreiranja monitoring sistema [76]. On je u cilju analize signala koristio spektrogram, i poredio je trenutna obeležja signala zvuka sa obeležjima dobijenim kada je mašina bila ispravna. Bilo kakvo odskakanje se detektovalo kao promena stanja ili neka vanredna situacija. Po njihovim rečima sistem je dobro radio prilikom eksperimentalne analize, ali zbog prevelikog broja mogućih neočekivanih situacija nije još dovoljno robustan da bi se koristio u pravim industrijskim uslovima. Sa druge strane Sadat [77] se skoncentrisao na istraživanje zvuka kod procesa sečenja i došao je do zaključka da posma-

tranjem čistog frekvencijskog spektra zvučnog signala na oko 3 kHz može da se detektuje istrošenost, što je jedan veliki korak napred, s obzirom da su prethodni algoritmi na tu temu bili bazirani ili na signalima vibracije ili akustičke emisije.

U poslednjoj deceniji dvadesetog veka istraživanja vezana za signale zvuka u industriji nisu bila dominantna u literaturi. Sa druge strane, izuzetno velike doprinose u razvijanju algoritama za obradu signala vibracije su imali McFadden i Wang [66, 67] koji su korištili spektrogram u kombinaciji sa naprednim tehnikama za obradu slike da detektuju otkaz rotirajuće mašine. Staszewski [78] je takođe imao prilično uspeha u korišćenju vremensko-frekvencijskih algoritama za detekciju stanja mašina na osnovu vibracije. Što se tiče akustičke emisije, prvi problemi su počeli da se javljaju kada se ustanovilo da, iako su ovi signali odlični za detekciju impulsnog pražnjenja, teško mogu da se koriste za detekciju istrošenosti mašina [34]. Takođe, kod samih rotirajućih aktuatora, gde se signal udara periodično ponavlja, akustička emisija ima problem da izdvoji korisnu informaciju o otkazu, što predstavlja dodatna ograničenja za korišćenje AE [60].

Nakon uvođenja signala vibracije u prava industrijska postrojenja polako dolaze na red i signali zvuka. Tako su početkom 21. veka Baydar i Ball prvi izvršili detaljnu komparativnu analizu informativnosti signala zvuka i vibracije u realnim industrijskim uslovima za detekciju otkaza motora. Jedna studija se bavila korišćenjem Wigner-Ville transformacije [35], dok se druga bavila *Wavelet* transformacijom [79]. Zaključak je bio da, i pored velike podložnosti akustičkih signala šumu, velika korist je cena samih senzora i činjenica da se merenja zvuka mogu vršiti sa određene udaljenosti od mašine, time eliminшуći potrebu za visoko-temperaturnim vibracionim senzorima i pratećim problemima vezanim za postavljanje senzora na aparaturu. Takođe, zaključeno je da istrošenost komponenti može da se detektuje koristeći vibraciju i zvuk, ali u nekim slučajevima zvučni signal pre detektuje promenu na mašini od signala vibracije. Veliki problem ostaje činjenica da šum kod zvučnog signala može značajno da smeta tačnoj estimaciji, a mora se обратити pažnja i na blizinu mikrofona mašini, pošto veliko udaljavanje od samog medijuma koji snima utiče na značajno smanjenje odnosa signal-šum.

Uporedo sa razvijanjem algoritama za primenu zvučnog signala u industriji, počinju da se razvijaju tehnologije za pametne građevine, umrežene senzorske sisteme, *internet-of-things* tehnologije i slično. Sa njima se otvaraju novi prostori za korišćenje akustičkih signala i novi izazovi koji treba da se premoste. U umreženim industrijskim postrojenjima detekcija loših ili zagađenih podataka (engl. *bad data detection*) postaje ozbiljan problem i algoritmi za njegovo rešavanje se rapidno razvijaju zadnjih deset godina. Sa druge strane, umreženost velike količine uređaja i senzora otvara mogućnost za analizu svakodnevnih scenarija na način na koji ranije to nije bilo moguće. Tako je problematika

klasifikacije akustičnih događaja dobila jako veliku popularnost u 21. veku [80]. Razvijanje svih ovih algoritama otvara vrata za potpuno nov pristup korišćenju akustičkih signala u industriji: ne samo za detekciju stanja jedne mašine, već i za istovremenu detekciju različitih događaja koji se u okolini te mašine dešavaju. Sa druge strane, algoritmi koji sprečavaju maliciozne napade na senzorske sisteme mogu da se koriste za detekciju šuma i na taj način robustifikuju rešenja za estimaciju stanja.

Uzevši u obzir sve ove probleme vezane za korišćenje zvučnog signala u industriji, kao i rezultate različitih oblasti koje se bave obradom zvuka i izolacijom događaja, osnovne karakteristike zvuka i problema njegove primene mogu se predstaviti na sledeći način:

- Zvučni signali mogu da detektuju otkaze i promene stanja rotacionih aktuatora i to na osnovu analize u vremenskom i frekvencijskom domenu. U smislu brzine detekcije mogu se meriti sa signalima vibracije (u nekim slučajevima su i brži), a praktičniji su za primenu na rotirajućim elementima od akustičke emisije.
- Akvizicija ovih signala se vrši indirektno, tako da se mogu snimati bez remećenja rada same mašine, na određenoj udaljenosti od nje.
- Izuzetno su podložni okolnom šumu i to je glavni razlog zašto se ne koriste u industrijskom okruženju gde je prisustvo šuma neminovno.
- Postoje razvijeni algoritmi za detekciju stanja mašina koristeći signale vibracije, međutim za njihovu primenu na signalima zvuka potrebni su i algoritmi za detekciju i/ili otklanjanje šuma koji bi na taj način izvršili robustifikaciju.
- Ključ efikasne detekcije šuma može da se krije u srodnim oblastima obrade podataka kao što su detekcija loših podataka i klasifikacija akustičkih događaja.

S tim u vezi, efikasan sistem za detekciju stanja mašina koristeći signale zvuka koji može da se primenjuje u industriji mora da sadrži sledeće stavke:

1. Jedinstveni način izdvajanja obeležja signala za srođan tip mašina.
2. Adaptivni algoritam sposoban da detektuje zašumljenost signala i, po mogućnosti, klasificiše tip šuma.
3. Algoritam sposoban da detektuje stanje (istrošenost ili promenu režima rada) mašine koristeći signale zvuka.

2.4 Studija slučaja: ventilatorski mlin u TEKO A1

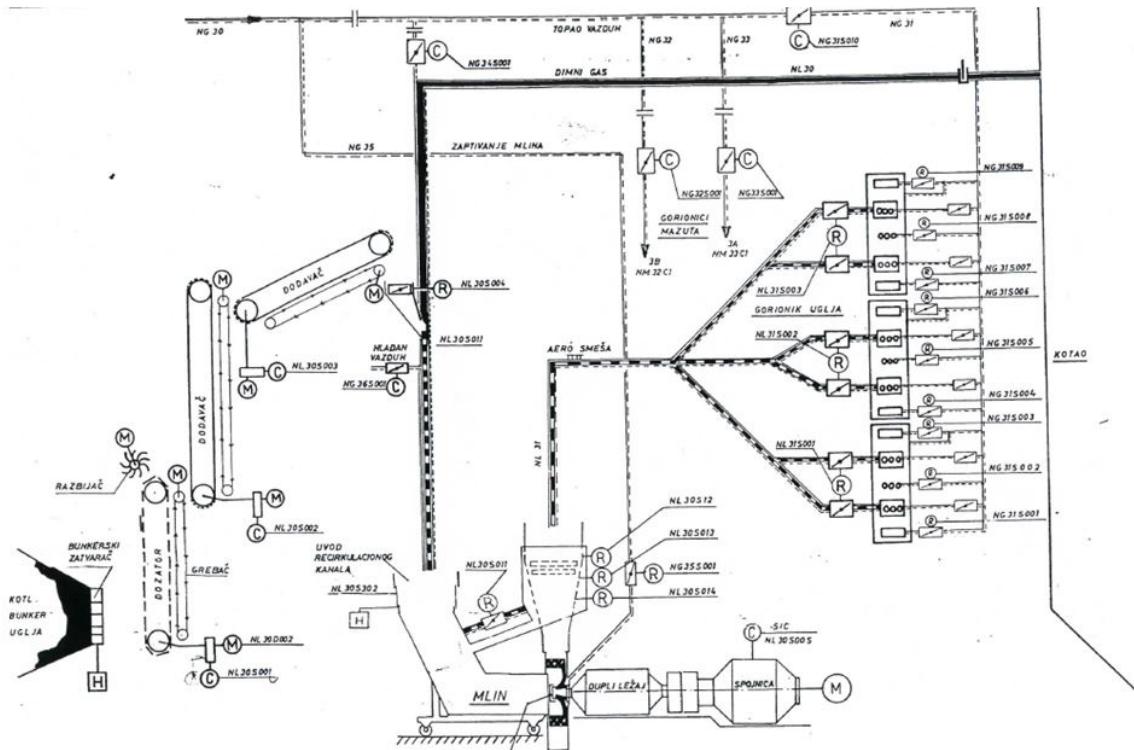
Svi algoritmi predloženi u ovoj tezi biće testirani na zvučnim signalima snimljenim u neposrednoj blizini ventilatorskog mlina u podsistemu za mlevenje uglja termoelektrane Kostolac A1 (TEKO A1) u Srbiji. U pitanju je blok jačine 110 MW, što je prilično mala vrednost ako se uzme u obzir prosečna snaga blokova u Srbiji.

2.4.1 Ventilatorski mlinovi

Najveći procenat električne energije u našoj zemlji proizvode upravo termoelektrane, tako da je razvijanje tehnika za procenu stanja njenih elemenata od jako velike važnosti. Mlinovi se nalaze u okviru kotlovskega postrojenja termoelektrana i oni imaju najveću ulogu prilikom mlevenja uglja. Ugalj (lignit) se iz bunkera, pomoću dozatora i mlinskog dodavača, dovodi u recirkulacioni kanal kroz koji pada u mlin. Delimično sušenje uglja počinje već ovde, što je značajno za ugalj sa visokim procentom vlage. Finalno sušenje uglja zajedno sa mlevenjem se obavlja u mlinu. Blok A1 ima osam mlinova istog kapaciteta, koji se nalaze na nultoj koti kotlarnice.

Za sušenje uglja se koristi sušeći medijum, koji predstavlja deo dimnih gasova visoke temperature koja se može regulisati mešanjem sa delom zagrejanog vazduha dovedenog u glavu recirkulacionog kanala. Ovakva smeša suvog uglja i vazduha, koja se naziva aerosmeša, se dalje vodi u mlinski separator na proveru finoće mlevenja. U separatoru se pod dejstvom inercije krupnije i nedovoljno samlevene čestice uglja odvajaju i vraćaju nazad na dodatno mlevenje u mlin. Aerosmeša se dalje, preko kanala, dovodi do trotažnih gorionika. To znači da se aerosmeša dovodi u ložište kroz tri zasebna vertikalno postavljena otvora na svakom gorioniku. Šematski prikaz kompletног mlinskog postrojenja može se videti na slici 2.19 [81].

Za potrebe mlevenja uglja u domaćim termoelektranama se najčešće koriste ventilatorski mlinovi. Oni funkcionišu tako što se udarne ploče, koje se nalaze unutar mlina, rotiraju oko centra i, pomoću sile udara i trenja, melju ugalj u veoma sitnu prašinu. U termoelektrani Kostolac A1 osnovna frekvencija rotacije radnog kola je 12.5 Hz i postoji 10 udarnih ploča unutar mlina. Primer jednog takvog mlina može se videti na slici 2.20 (a). Udarne ploče unutar mlinova se vremenom troše i potrebno ih je servisirati u proseku na svakih 1200-1500 radnih sati (oko 8 radnih nedelja). U suprotnom se ugalj u mlinu sve lošije melje i potrebno je više vremena za dostizanje optimalne veličine mlevenih čestica. To može da dovede do čestih zagušenja i sporadičnog gubljenja kapaciteta mlina. Naravno, vreme posle koga je potrebno vršiti remont može značajno da varira i zavisi od

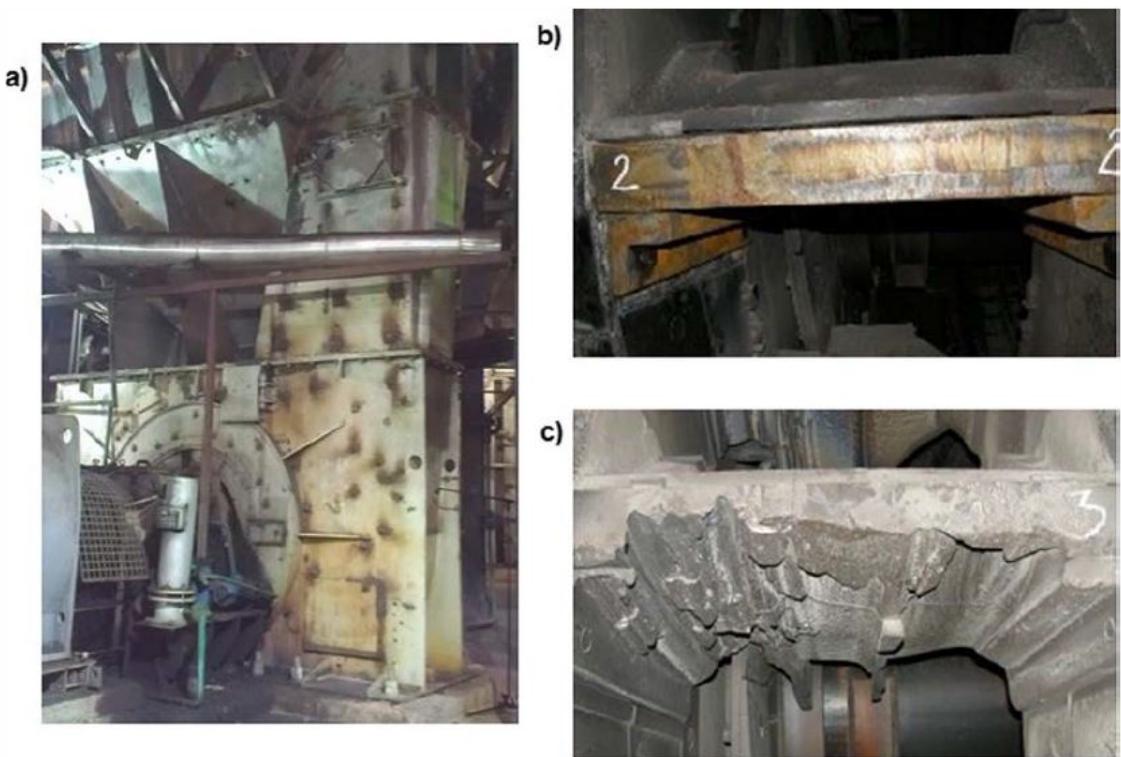


Slika 2.19: Sistem mlinskog postrojenja

mnogih činilaca među kojima su kvalitet samih ploča, granulacija uglja koji se usitjava i prisutnost drugih materijala unutar mlinja kao što su pesak, kamenje i sl. Na slikama 2.20 (b) i 2.20 (c) su prikazane jedna zdrava i jedna istrošena udarna ploča, respektivno.

Logičan metod za estimaciju efikasnosti mlini bi bio pristup baziran na modelu koji se sastoji od kreiranja matematičkog modela koji će opisati zavisnost ovih i drugih parametara od stanja udarnih ploča. U literaturi postoje razni pokušaji pravljenja matematičkih modela mlinova za mlevenje uglja, počevši od prve detaljne analize procesa mlevenja sredinom prošlog veka [82]. U aktuelnoj literaturi postoji više pristupa kreiranja modela mlinova, neki od njih imaju za cilj generisanje upravljanja [83], dok su drugi sa ciljem praćenja stanja [84]. Ono što je zajedničko za sve njih je jako velika kompleksnost modela. Naime, model koji uzima u obzir sve relevantne podatke kao što su toplota, masa, snaga su izuzetno nelinearni modeli visokog reda, i ne mogu značajno da se pojednostavljaju linearizacijom. Iz tog razloga se mnogo češće u te svrhe primenjuju tehnike bazirane na podacima koje koriste samo snimljene podatke, ne uzimajući u obzir dinamiku mlini.

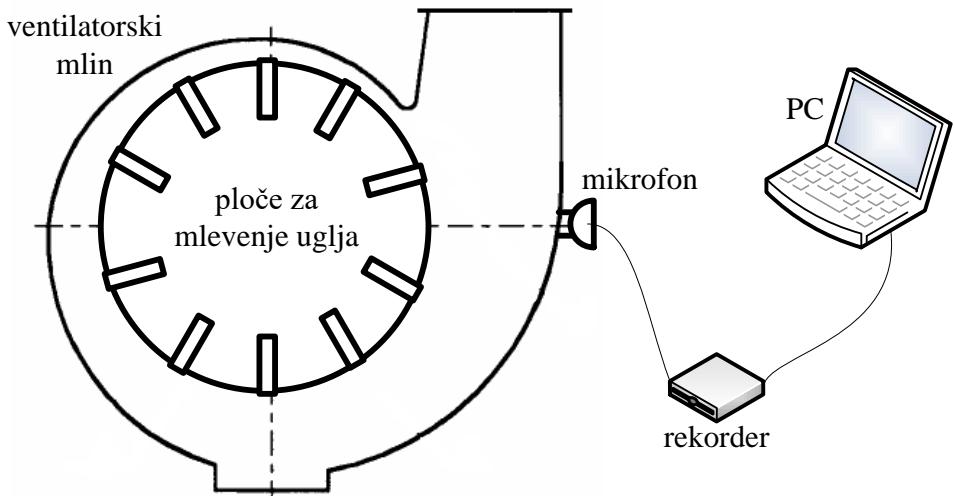
Što se tiče ventilatorskih mlinova u termoelektranama, unapređenje njihove efikasnosti je aktuelan problem i postoje razne ideje za omogućavanje njihovog ekonomičnijeg rada. Neka istraživanja [85] se koncentrišu na poboljšanje kvaliteta udarnih ploča kako bi potreba za remontom bila ređa, dok se druga koncentrišu na redukovanje količine krup-



Slika 2.20: (a) Ventilatorski mlin u termoelektrani Kostolac; (b) Zdrava udarna ploča; (c) Istrošena udarna ploča.

nih čestica uglja koje prolaze do sistema za sagorevanje nadogradnjom dodatnih zaštitnih ploča unutar samog mlina [86]. Na taj način se značajno doprinosi produženju životnog veka mlina i smanjenju štetnih efekata istrošenih ploča; međutim, u ovim predloženim metodama i dalje postoji problem procene tačnog trenutka kada je potrebno izvršiti remont.

Do sada je jedini način da se utvrdi stanje udarnih ploča bio vizuelna inspekcija mlina koja zahteva zaustavljanje čitavog pod sistema za mlevenje uglja, otvaranje mlina i provjera ploča. Ova procedura je vremenski veoma zahtevna, a ako se ustanovi da je zamena nepotrebna, finansijski gubitak za Elektroprivredu Srbije usled zaustavljanja ovog sistema i smanjenja proizvodnje električne energije je veliki. Primera radi, kako većina termoelektrana u Srbiji ima blokove snage 300 MW i ako je prosečna cena struje 60 € po MWh, onda je cena zaustavljanja bloka na šest sati radi remonta oko 100.000 €. Dalje, ako smanjenje proizvodnje električne energije uzrokuje potrebu za dodatnim uvozom, trošak se značajno povećava.



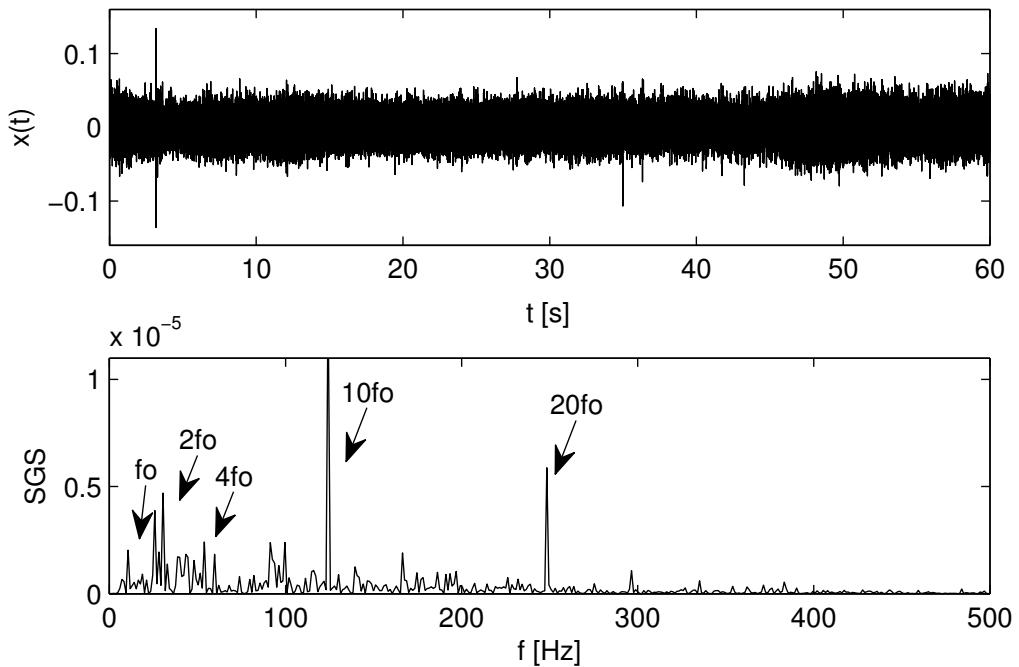
Slika 2.21: *Sistem za akviziciju signala.*

2.4.2 Akvizicija zvučnog signala

Sistem za snimanje zvučnih signala sa ventilatorskog mlina predstavljen je na slici 2.21. U toku svake sesije snimanja mikrofon je postavljan na istu poziciju, na udaljenosti od nekoliko milimetara od mlina. Akustički signali su snimani sa AKG C451 mikrofonom i frekvencijom odabiranja od 48 kHz, sa rezolucijom od 24 bita.

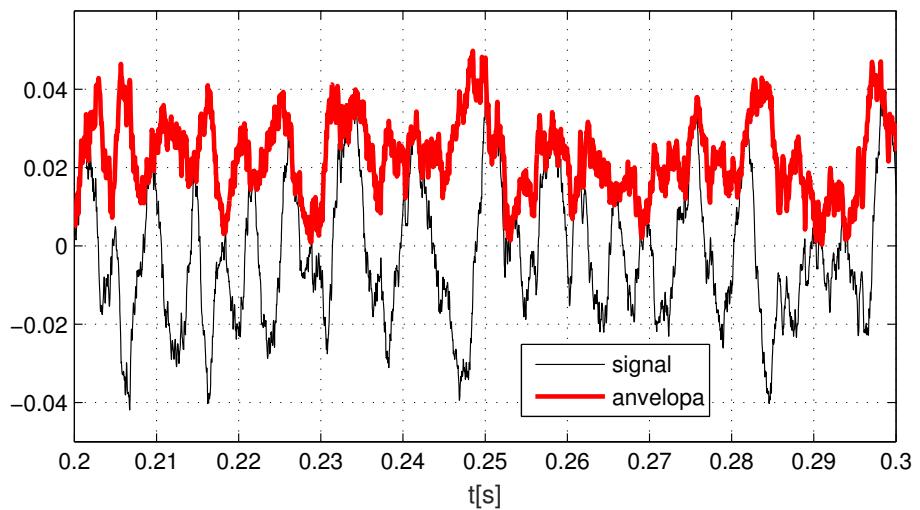
Potrebno je napomenuti da je snimanje akustičkih signala izvršeno u prostoru sa jako izraženim zvučnim zagađenjem, pošto se veliki broj mašina nalazi u neposrednoj blizini mesta na kome je merenje vršeno. Mikrofon je usmeren ka mlinu i postavljen na bočnoj strani kako bi se minimizirao uticaj okoline i motora koji pokreće mlin i kako bi zvučni potpis samih ploča maksimalno došao do izražaja. Međutim, i pored ovih zaštitnih mera, uticaj okolnih uređaja je izuzetno jak u snimljenim signalima, što odgovara realnim uslovima koji se mogu naći u industrijskom okruženju.

Za dalji razvoj algoritama potrebno je uvesti neke prepostavke vezane za snimljeni zvučni signal. Prva je prepostavka o ciklostacionarnosti, odnosno prepostavka da se statističke osobine signala ciklično menjaju sa rotacijom mлина u toku jedne sesije snimanja. Prepostavka ciklostacionarnosti signala zvuka i vibracije rotacionih aktuatora je opšte prihvaćena u literaturi [87] i često je korišćena za potrebe praćenja stanja mašina. Takođe je ustanovljeno da je perioda ciklostacionarnosti striktno vezana za periodu rotacije aktuatora. Druga prepostavka je da se promenom stanja udarnih ploča menja i karakteristika zvuka na neki nepoznat način, odnosno ciklostacionarnost prestaje da važi. Ovo je takođe jedna od dobro ustanovljenih prepostavki koja je često korišćena u literaturi za detekciju promene stanja rotacionih aktuatora [28].



Slika 2.22: Zvučni signal snimljen u neposrednoj blizini mlina u vremenskom domenu (gore) i frekvencijskom domenu (dole).

Pretpostavka o ciklostacionarnosti donekle olakšava obradu zvučnog signala jer omogućava analizu u vremenskom i frekvencijskom domenu, bez zalaženja u vremensko-frekvencijske transformacije, dokle god je vremenski opseg posmatranog signala značajno veći od periode rotacije mlina. Signal trajanja 60 s u vremenskom domenu i njegova predstava u frekvencijskom (u formi spektralne gustine snage) može se videti na slici 2.22. U vremenskom domenu signal liči na beli šum, dok se u frekvencijskom domenu vide jasno izražene prostoperiodične komponente. Najjače su izraženi pikovi na osnovnoj frekvenciji rotacije mlina $f_0 = 12.5 \text{ Hz}$ i njenim višim harmonicima, a posebno su izraženi pikovi na $10f_0$, $20f_0$, itd. Objašnjenje za ovu pojavu može se naći u činjenici da postoji 10 udarnih ploča koje rotiraju oko centra mlina, tako da je osnovna frekvencija prolaska ploče pored mikrofona upravo $f_p = 10f_0$, pa je logično da ova učestanost i njeni viši harmonici posebno dolaze do izražaja. U skladu sa trendovima u literaturi, veliki broj algoritama predloženih u ovoj disertaciji koristi anvelopu signala u vremenskom domenu dobijenu Hilbertovom transformacijom. Izgled anvelope signala zvuka može se videti na slici 2.23.



Slika 2.23: Snimljen zvučni signal i njegova anvelopa.

Glava 3

Detekcija kontaminacije akustičkog signala

Informativnost i praktičnost korišćenja akustičkih signala za estimaciju stanja je potvrđena u literaturi i već diskutovana u okviru ove teze. Uprkos tome, glavni razlog za njihovo retko korišćenje u industriji je njihova velika podložnost okolnom šumu koji je uvek prisutan u industrijskom okruženju. Naime, osnovni uslov za implementaciju algoritama za estimaciju stanja u industriji je njihova robusnost na kontaminirana merenja [88]. S tim u vidu, prvi korak u povećanju primenjivosti akustičkih signala u industriji je razvijanje efikasnog algoritma za detekciju kontaminacije koji će na taj način robustifikovati postojeće ili nove algoritme za detekciju stanja.

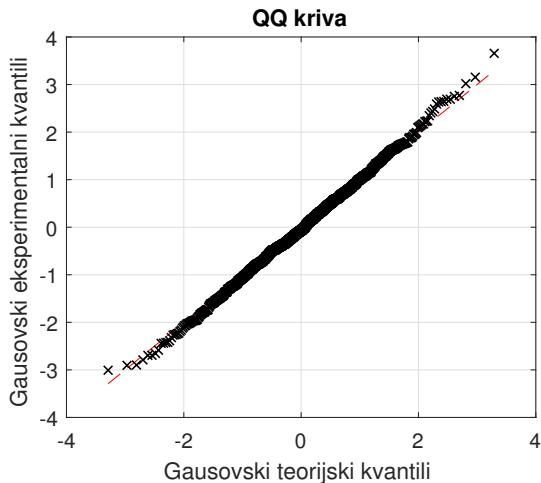
Klasične metode filtracije šuma u frekvencijskom domenu nisu primenjive u opštem slučaju iz više razloga. Prvo, potrebno je proceniti na kojim frekvencijama se šum javlja, što automatski znači da smo se ograničili samo na određen tip šuma. Sa druge strane, šum je jako retko koncentrisan na nekom uskom frekvencijskom opsegu, tako da je često nemoguće izolovati ga bez velikog oštećenja korisnog signala. Primera radi, impulsni šum koji je izuzetno čest u industrijskom okruženju ima izražene komponente na svim učestanostima, tako da ga je jako teško standardnim filtrima odstraniti. S obzirom da metod filtracije šuma nije dovoljno pouzdan, razne metode su počele da se razvijaju koje rade samo detekciju kontaminacije. Opravданje za ovo pojednostavljenje problema leži u činjenici da za dobro funkcionisanje sistema za estimaciju stanja nije neophodno „popraviti“ kontaminiran signal, već je dovoljno samo sprečiti kontaminaciju da dođe do estimatora stanja. S tim u vidu, algoritam koji uspeva da detektuje šum i odbaci kontaminirane signale može da se koristi u cilju robustifikacije sistema za prediktivno održavanje.

Imajući u vidu značaj ove oblasti, detekcija kontaminacije kod akustičkih signala je

prepoznata kao ozbiljan problem u poslednjih nekoliko godina i oblast detekcije loših podataka je postala izuzetno popularna u modernoj literaturi [89]. Zbog brzog razvoja *internet-of-things* tehnologija i umrežavanja inteligentnih sistema, detekcija loših podataka se najčešće odnosi na otkrivanje malicioznih napada na estimatore stanja u vidu podmetanja netačnih podataka [90]. Većina ovih algoritama se oslanja na prethodno poznavanje modela procesa, na generisanje reziduala koristeći alate kao što je filtracija Kalmanovim filtrom [91, 92], pa čak i na korišćenje više senzora [93] čime se uspešno detektuju kontaminirana merenja. S obzirom da je neophodan model u prostoru stanja često jako teško dobiti, taj uslov predstavlja priličnu poteškoću u implementaciji ovih algoritama. Algoritmi razvijani u okviru ove disertacije ne prepostavljaju poznavanje modela u prostoru stanja već estimiraju nominalne statističke parametre akustičkih signala u kojima se ne nalazi kontaminacija, pa onda porede ove karakteristike sa karakteristikama snimljenog signala.

Zbog kompleksnosti zvučnog signala i velike količine informacija koja se može naći u njemu kako u nominalnom radu, tako i u kontaminiranoj sredini, neophodno je reći par reči o tome šta smatramo kontaminacijom, a šta predstavlja nominalni signal. Naime, prepostavlja se da je akustički signal snimljen u industrijskom okruženju u kojem postoje konstantni izvori buke. Dakle, u svakom trenutku snimak zvuka sadrži signale koje proizvodi rotacioni aktuator koji se snima, ali i ostale mašine i instrumenti koji se nalaze u okolini. Korektnim postavljanjem mikrofona se osigurava da predmet snimanja ima jači zvučni potpis od ostalih aparatura, ali to ni na koji način ne umanjuje činjenicu da su neželjeni zvukovi uvek prisutni. Međutim, dokle god važi prepostavka o stacionarnosti, odnosno dokle god snimljeni zvučni signal ima iste karakteristike u jednoj sesiji snimanja, očekuje se od algoritma za estimaciju stanja da, uprkos višku informaciju, uspešno izvrši procenu stanja posmatranog aktuatora. Ako se, sa druge strane, u okviru signala javi kratkovremenski šum kao što je zvuk koji se proizvodi u toku remonta ili zvuk konverzacije prolaznika, to se smatra kontaminacijom i ne očekuje se od algoritama za estimaciju stanja uspešno funkcionisanje sa signalima zagađenim na taj način. Dakle, problem detekcije kontaminacije zvučnog signala se odnosi na detekciju šumova koji imaju ograničeno trajanje u vremenu i narušavaju prepostavku o stacionarnosti.

U okviru ovog poglavlja biće ukratko opisan osnovni alat korišćen u razvijanju algoritama za detekciju kontaminacije, a to su QQ krive. Dalje, biće prikazani algoritmi razvijeni u okviru ove disertacije, prvenstveno adaptivni algoritam za detekciju kontaminacije korišćenjem QQ kriva i dva predloga algoritama za klasifikaciju kontaminacije. Jedan od njih koristi QQ krive i Neyman-Pearson test, dok je drugi baziran na korišćenju kepstralnih koeficijenata i metode nosećih vektora.

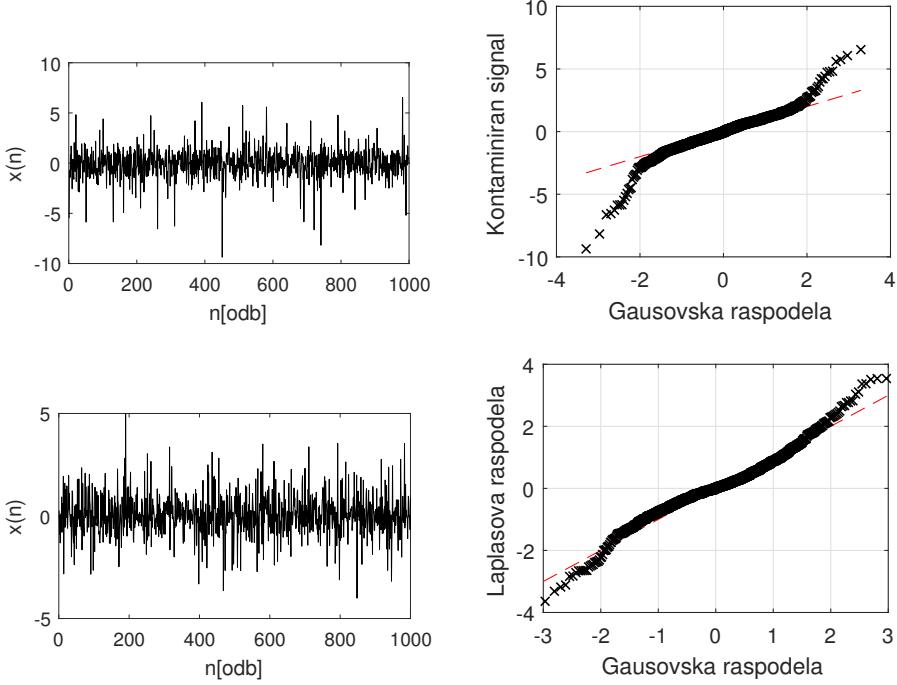


Slika 3.1: *Eksperimentalno dobijena Gausova raspodela u odnosu na teorijsku.*

3.1 QQ krive

QQ krive su veoma efikasan statistički alat koji se koristi za poređenje očekivane i dobijene raspodele verovatnoće [94]. Ovaj grafik se dobija skiciranjem kvantila mernog signala u odnosu na odgovarajući kvantil očekivane raspodele. Kvanti predstavljaju tačke u statističkoj raspodeli koje odgovaraju rangu sortiranih vrednosti te raspodele, a kod kontinualnih slučajnih promenljivih, kvantili su u stvari inverzija funkcije raspodele. Ako signal odgovara očekivanoj raspodeli verovatnoće, onda će se sve tačke QQ krive nalaziti na približno ravnoj liniji $x = y$, odnosno na liniji koja se prostire kroz koordinatni početak pod uglom od 45° u odnosu na ordinatu i apscisu. Na slici 3.1 može se videti primer QQ krive eksperimentalno dobijenih odbiraka Gausove raspodele sa nultom srednjim vrednošću i jediničnom varijansom skiciranih u odnosu na istu tu teorijsku raspodelu.

Korišćenje jednog ovakvog algoritma za analizu signala ne omogućava samo poređenje dve funkcije raspodele, već i identifikaciju raspodele posmatranog signala [95]. Primera radi, ako se odstupanja od $x = y$ linije javljaju na krajevima krive, to znači da merena raspodela ima drugačije repove od očekivane. Sa druge strane, ako sve tačke krive leže na liniji, ali ta linija nije pod uglom od 45° , to znači da je u pitanju očekivana raspodela, ali srednja vrednost i varijansa se razlikuju od očekivanih. Pomoću ovih pravila lako se može pretpostaviti izgled prave funkcije raspodele u odnosu na očekivanu raspodelu. Na primer, za Gausovski raspodeljen signal zagađen impulsnim šumom se očekuje QQ kriva sa velikim repovima, kao na slici 3.2 gore. Sa druge strane, ako se raspodele dobijenog i očekivanog signala značajno razlikuju, tada će odstupanje od $x = y$ ose biti izraženo za male i velike vrednosti kvantila. Ovo se može videti na slici 3.2 (dole) gde se Laplasovski raspodeljeni signal predstavlja na QQ krivoj u odnosu na teorijsku Gausovu raspodelu.



Slika 3.2: Kontaminirana Gausova raspodela (gore) i Laplasova raspodela (dole) sa odgovarajućim QQ krivama.

Grafik ukazuje na to da dobijeni odbirci imaju veće vrednosti od Gausove raspodele, ali i da za niže vrednosti postoji talasanje na krivoj što govori o neslaganju i u oblasti koja je bliska nuli.

Pomoću ovih osobina QQ krive moguće je proširiti njenu primenu na estimaciju statistika prvog i drugog reda (srednje vrednosti i standardne devijacije) stohastičkog procesa. Ako izmereni odbirci z_i , gde je $i = 1, \dots, N$, formiraju raspodelu $F(z)$, onda može da se dobije sortirana neopadajuća sekvenca x_i gde je $x_i \leq x_j$ za $i < j$. Ovde N predstavlja broj uzetih odbiraka. Posmatrajući sortiranu sekvencu x_i , može se dobiti relacija [96] za uslovnu verovatnoću da realizacija x ima rang i u dатој секвenci

$$P(i|x) = \binom{N-1}{i-1} F^{i-1}(x) (1 - F(x))^{N-i}. \quad (3.1)$$

Dalje, uslovno matematičko očekivanje $m_{i|x}$ i uslovna varijansa $\sigma_{i|x}^2$ slučajne promenljive i uvezši odbirak x su [97]:

$$\begin{aligned} m_{i|x} &= 1 + (N-1) F(x) \\ \sigma_{i|x}^2 &= (N-1) F(x) [1 - F(x)]. \end{aligned} \quad (3.2)$$

Vrednost uslovne varijanse je jako mala u odnosu na i , tako da je rang i slučajne promenljive x u okolini uslovnog matematičkog očekivanja $m_{l|x}$. Kao direktna posledica te osobine [97] važi relacija

$$x_i \approx F^{-1}(q_i); q_i = \frac{i - 0.5}{N}. \quad (3.3)$$

Ovde je $F^{-1}(\cdot)$ inverzija funkcije raspodele $F(\cdot)$, tako da je veza između x_i i odgovarajućih kvantila očekivane raspodele približno linearna, pod uslovom da je prepostavka o raspodeli tačna. Tako se QQ kriva može definisati kao grafik sortirane sekvene x_i u odnosu na veličinu $F^{-1}(q_i)$. Jednačina 3.3 može da se predstavi u formi linearne regresije kao

$$x_i = m + \sigma F_0^{-1}(q_i) = m + \sigma \bar{q}_i, \quad (3.4)$$

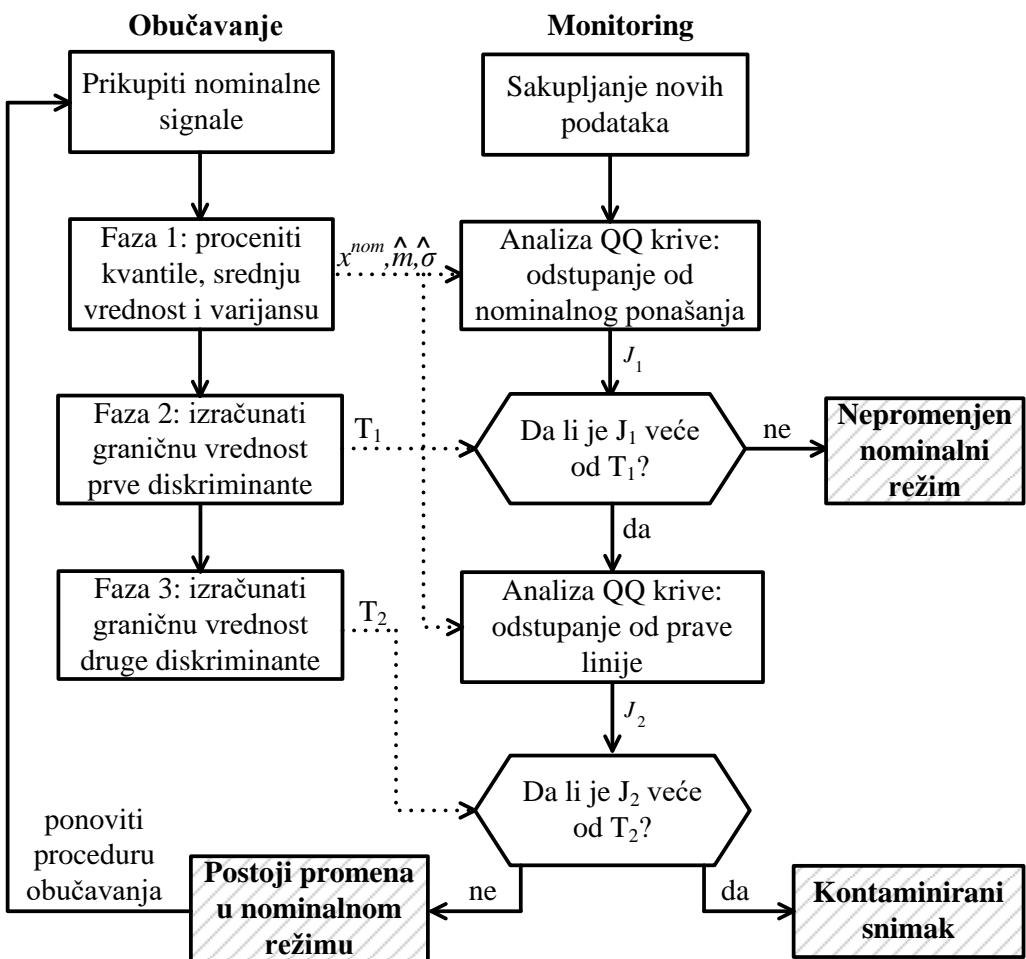
gde je $F_0^{-1}(q_i)$ funkcija raspodele sa nultom srednjom vrednošću i jediničnom varijansom. Na ovaj način moguće je estimirati nepoznate statističke momente prvog i drugog reda iz dobijene sekvene koristeći algoritam najmanjih kvadrata kao

$$\begin{bmatrix} \hat{m} \\ \hat{\sigma} \end{bmatrix} = (\Sigma^T \Sigma)^{-1} \Sigma^T X. \quad (3.5)$$

Ovde parametri \hat{m} i $\hat{\sigma}$ predstavljaju procenu srednje vrednosti i standardne devijacije, respektivno, a matrica Σ i vektor X su:

$$\Sigma = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ \bar{q}_1 & \bar{q}_2 & \cdots & \bar{q}_N \end{bmatrix}^T; X = \begin{bmatrix} x_1 & x_2 & \cdots & x_N \end{bmatrix}^T. \quad (3.6)$$

Estimirane vrednosti prvog i drugog momenta u iz jednačine 3.5 biće korištene za detekciju devijacije dobijene raspodele signala od očekivane.



Slika 3.3: Blok dijagram izvršavanja algoritma za detekciju kontaminacije.

3.2 Algoritam za adaptivnu detekciju kontaminacije

Novi adaptivni algoritam za detekciju kontaminacije zvučnog signala je razvijen u okviru ove disertacije i testiran na primeru opisanom u poglavljju 2.4. Ovde se koristi tehnika QQ krivi imajući u vidu sledeću premisu: ako oblik funkcije raspodele snimljenog signala odgovara raspodeli nominalnog signala, ali su srednja vrednost i varijansa drugačiji (odnosno eksperimentalni odbirci leže na ravnoj liniji QQ krive, ali ne pod uglom od 45°) ovo znači da su neke komponente zvučnog signala promenile svoj intenzitet i postoje promena u celokupnom nominalnom režimu. To može da se desi zbog promene stanja mašine koja se snima ili okolnih aparatura i takva promena ne treba da se protumači kao kontaminacija. Ako, sa druge strane, tačke na QQ krivoj ne formiraju pravu liniju, to ukazuje da je raspodela drugačija od očekivane i postoje dodatne akustičke komponente u vidu kontaminacije.

Pošto će se QQ krive u ovom algoritmu koristiti u cilju lakšeg poređenja raspodele

signalna, potrebna je prilično tačna informacija o nominalnoj raspodeli. Nominalno ponašanje signala zavisi od mnogih faktora uključujući strukturu i poziciju samog aktuatora koji se snima, kao i broj i tip ostalih mašina u okolini koje su u funkciji. Iz tog razloga je inicijalni korak ovog algoritma, u kome se estimira nominalna funkcija raspodele, izuzetno važan i mora da se obavi svaki put kada postoji značajna promena u okruženju aktuatora. Na taj način se obezbeđuje adaptivna priroda algoritma. Struktura predložene metode prikazana je na slici 3.3.

Obučavanje algoritma

Najznačajniji korak za uspešnu detekciju kontaminacije je tačna pretpostavka o nominalnom statističkom ponašanju signala. Često se u ovakvim slučajevima prepostavi neka konkretna raspodela (uglavnom Gausova ili Laplasova), pa se traže njeni parametri kako bi što vernije odgovarala snimljenom nominalnom signalu. Onog trenutka kada postoji saznanje o konkretnoj teorijskoj raspodeli koja se očekuje, lako je izračunati i očekivane kvantile. Taj princip ne zahteva mnogo odbiraka snimljenog signala, međutim u slučaju pogrešno prepostavljene raspodele može da ima značajne greške u estimaciji. S obzirom da se kod zvučnog signala prilično jednostavno dobija statistički relevantan broj odbiraka (ako je prosečna frekvencija odabiranja snimka 48 kHz, za samo nekoliko sekundi se dobija po nekoliko stotina hiljada odbiraka), kvantili se neće računati na ovaj način već eksperimentalno. Da bi se održala statistička relevantnost testa, dužina nominalnog snimka L , koja se koristi za analizu, mora da bude značajno veća od dužine prozora koji se testira N . Obučavanje algoritma se sprovodi u tri faze.

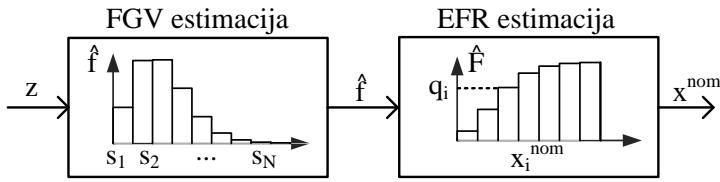
(1) *Prva faza:* Empirijska funkcija raspodele (EFR) nominalnog snimka x koji je dugačak L odbiraka je estimirana kao na slici 3.4. Prvo se estimira funkcija gustine verovatnoće (FGV) koristeći histogramsku metodu, tako što se odbirci podele u intervale s_j , $j \in [1, N]$ i računa se j -ti segment FGV kao

$$\hat{f}_j = \frac{L_j}{L\Delta s}, \quad (3.7)$$

gde je L_j broj odbiraka u intervalu $[s_j, s_{j+1}]$. Posle toga se EFR računa kao

$$\hat{F}_j = \sum_{n=0}^j \hat{f}_j \Delta s. \quad (3.8)$$

Koristeći ovako dobijenu EFR, vrednost x_i^{nom} koja odgovara kvantilu $q_i = (i - 0.5) / N$



Slika 3.4: Prva faza obučavanja: estimacija nominalnih kvantila.

može da se estimira direktno iz jednačine 3.3. Osim x^{nom} , izlazi ove faze su srednja vrednost \hat{m}_{nom} i standardna devijacija $\hat{\sigma}_{nom}$ nominalnih odbiraka određena kao

$$\begin{aligned}\hat{m}_{nom} &= \frac{1}{L} \sum_{i=1}^L x_i, \\ \hat{\sigma}_{nom} &= \sqrt{\frac{1}{L-1} \sum_{i=1}^L (x_i - \hat{m}_{nom})^2}.\end{aligned}\tag{3.9}$$

(2) *Druga faza:* U ovoj fazi se određuje prvi prag za poređenje na osnovu koga će se određivati da li je došlo do bilo kakvih odstupanja u odnosu na očekivanu nominalnu raspodelu određenu u prethodnom koraku. Nominalni snimak se deli na segmente dužine N odbiraka i svaki segment se sortira u neopadajuću sekvencu y_i . Prva metrika, J_1 , predstavlja srednju kvadratnu grešku odstupanja datog segmenta od estimiranih kvantila

$$J_1 = \frac{1}{N} \sum_{i=1}^N (y_i - x_i^{nom})^2.\tag{3.10}$$

Ovo se ponavlja kroz sve nominalne segmente i granica T_1 se dobija tako što se fiksira verovatnoća lažnog alarma $P(J_1 \geq T_1) = 0.05$. Ako se srednja kvadratna greška nalazi iznad ove granice to znači da je verovatnoća da je ona dobijena pod pretpostavkom nominalne raspodele J_1 manja od 5%. U tom slučaju algoritam će označiti ovaj segment sumnjivim i nastaviće da radi dalje provere. U suprotnom zaključuje se da ne postoji dovoljno dokaza o značajnim odstupanjima od pretpostavljene raspodele.

(3) *Treća faza:* Ako je promena detektovana u prethodnom koraku još jedan test je potreban da bi se utvrdilo koja vrsta promene je u pitanju. Mera J_2 se koristi za računanje devijacije snimljenog segmenta od prave linije na QQ krivoj. Ako je J_2 malo, merenje ima istu raspodelu kao nominalni signal ali drugačiju srednju vrednost i varijansu. U suprotnom, merena raspodela se značajno razlikuje od očekivane i smatra se da je došlo do kontaminacije. Srednja vrednost \hat{m}_{meas} i standardna devijacija $\hat{\sigma}_{meas}$ snimljenog signala mogu da se odrede koristeći jednačinu 3.5, gde su \bar{q}_i kvantili nominalne raspodele sa

nultom srednjom vrednošću i jediničnom varijansom i računaju se kao

$$\bar{q}_i = \frac{1}{\hat{\sigma}_{nom}} (x_i^{nom} - \hat{m}_{nom}). \quad (3.11)$$

Ako imamo vrednosti momenta prvog i drugog reda, aproksimacija prave linije na QQ krivoj x^{maes} , koja najbolje odgovara izdvojenom segmentu može da se napiše u funkciji nominalnih kvantila kao

$$x_i^{maes} = M + S x_i^{nom}, \quad (3.12)$$

gde su

$$M = \hat{m}_{maes} - \frac{\hat{\sigma}_{maes}}{\hat{\sigma}_{nom}}; S = \frac{\hat{\sigma}_{maes}}{\hat{\sigma}_{nom}}. \quad (3.13)$$

Druga mera, J_2 , predstavlja srednje kvadratno odstupanje snimljenog segmenta of kvantila x^{maes}

$$J_2 = \frac{1}{N} \sum_{i=1}^N (y_i - x_i^{maes})^2. \quad (3.14)$$

Ovo se ponavlja kroz sve nominalne segmente i, ponovo, granica T_2 se dobija tako što se fiksira verovatnoća lažnog alarma $P(J_2 \geq T_2) = 0.05$.

Monitoring signala

U monitoring stadijumu algoritam jednostavno koristi podatke izračunate u toku obučavanja i na osnovu njih donosi zaključke o kontaminaciji. S obzirom da su nominalni kvantili, granice, estimacije srednje vrednosti i varijanse već određene, generisanje QQ krive u monitoring režimu je računarski lako izvodljivo i može da se obavi u realnom vremenu. Snimljeni signali se dele na segmente i za svaki segment se donosi odluka R kao

$$R = \begin{cases} 0, & J_1 < T_1 \\ 1, & J_1 \geq T_1 \wedge J_2 < T_2 \\ 2, & J_1 \geq T_1 \wedge J_2 \geq T_2 \end{cases}. \quad (3.15)$$

Prvo se računa mera J_1 iz jednačine 3.10 i poredi se sa granicom T_1 koja je dobijena u fazi obučavanja. Ako je vrednost srednje kvadratne greške manja od prve granice smatra se da je segment nominalan, izlaz algoritma usvaja vrednost $R = 0$ i merenje može da se koristi dalje za potrebe estimacije stanja. Ako je, sa druge strane, vrednost J_1 veća od izračunate granice ovo ukazuje na to da je ili došlo do promene nominalnog režima ili je segment kontaminiran šumom. Mera iz jednačine 3.14 se tada koristi radi dodatne analize. Ako je J_2 veća od granice T_2 to znači da je došlo do kontaminacije, algoritam

usvaja vrednost $R = 2$ i segment se odbacuje. Ako se, sa druge strane, druga mera nalazi ispod granice to znači da se raspodela segmenta poklapa sa nominalnom raspodelom ali sa drugačijom srednjom vrednošću i varijansom i izlaz algoritma usvaja vrednost $R = 1$. Ovo znači da postoji promena u nominalnim statističkim parametrima signala i savetuje se ponavljanje procedure obučavanja. Posle ove analize algoritam nastavlja na sledeći segment snimka.

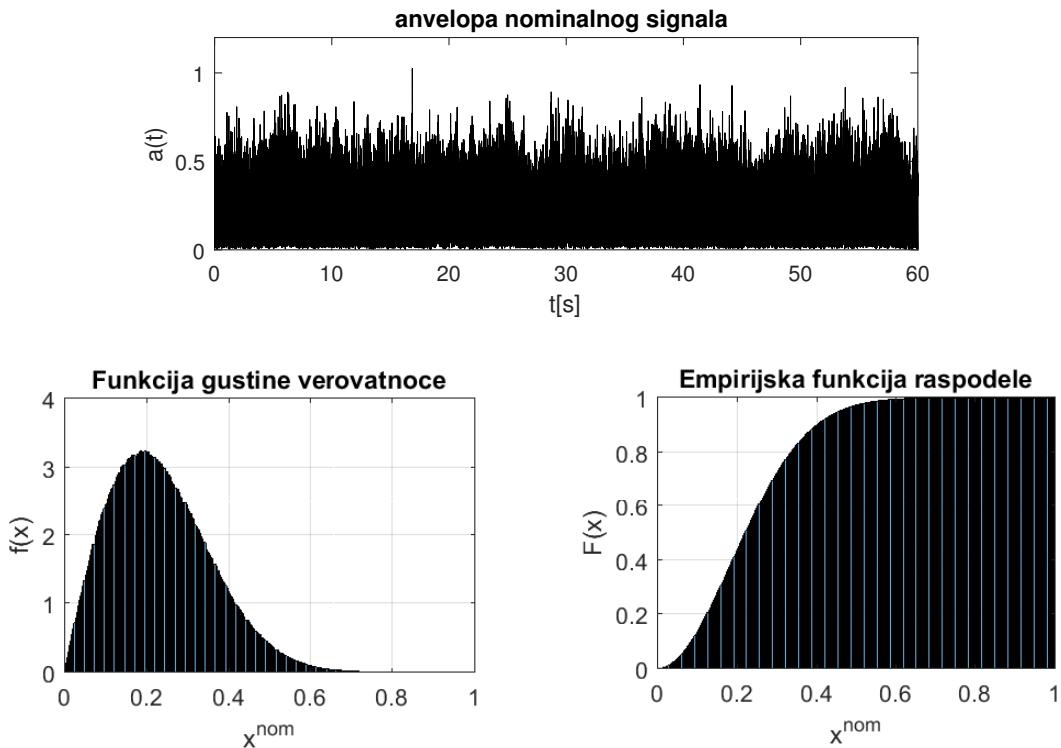
Rezultati algoritma

Predloženi algoritam testiran je na signalima zvuka dobijenim na ventilatorskom mlinu iz poglavlja 2.4. Sekvenca snimljenog eksperimenta je dugačka 18 minuta, a segmenti koji se analiziraju su dužine 48.000 odbiraka, odnosno trajanja 1 s. Preklapanje između segmenata je 50%. U okviru eksperimenta se obezbedilo da dobijenih 18 minuta snimka sadrži dugačke sekvene nekontaminiranog signala ali i statistički relevantnu količinu kontaminacija. Postoje dve vrste kontaminacija koje su snimljene: jedna je u vidu impulsnog šuma realizovanog povremenim udarcima čekića o sam mlin i njegovu okolinu, a druga je u vidu kontaminacije govornim signalom koja je simulirana tako što je snimljeno pričanje u okolini mikrofona. Obe ove vrste kontaminacija su česte u industriji - impulsni šum se javlja uvek kada se vrši remont neke mašine u postrojenju, dok se kontaminacija govorom može desiti svaki put kada radnici prolaze u blizini lokacije na kojoj se snimanje vrši. Osim ovih sadržaja, u eksperimentalnom snimku se takođe nalazi jedan segment u okviru kojeg se pomera mesto mikrofona u toku snimanja, i na taj način se simulira promena statističkih parametara nominalnog režima.

Prvi korak u testiranju algoritma je obavljanje procedure obučavanja. Uzet je snimak zvuka bez kontaminacija dužine 60 s (odnosno 2.880.000 odbiraka). Preliminarna obrada ovog signala podrazumeva računanje Hilbertove transformacije u cilju dobijanja envelope. Sve dalje analize sa slike 3.3 biće rađene koristeći upravo anvelopu signala.

Proces dobijanja kvantila prikazan je na slici 3.5. Koristeći histogramsku metodu estimirana je funkcija gustine verovatnoće envelope signala i može se primetiti da zaista nema standardni oblik. Ona nije simetrična, različita je od nule samo za pozitivne vrednosti promenljive i prilično se teško može poklopiti sa nekom već postojećom popularnom raspodelom. Ovo dodatno opravdava odluku da se koristi empirijski način za proračun funkcije raspodele. Osim kvantila, u ovoj fazi su određene i srednja vrednost i standardna devijacija envelope signala, kao u jednačini 3.9.

Po završetku prve faze obučavanja potrebno je odrediti mere J_1 i J_2 u okviru druge i treće faze kao u jednačinama 3.10 i 3.14. J_1 se može proceniti sa QQ krive kao odstupanje

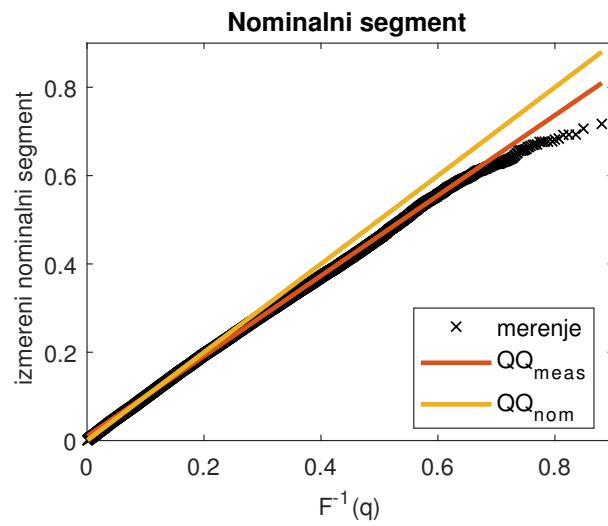


Slika 3.5: Hilbertova transformacija nominalnog signala (gore), estimirana funkcija gustine verovatnoće (levo) i empirijska funkcija raspodele (desno).

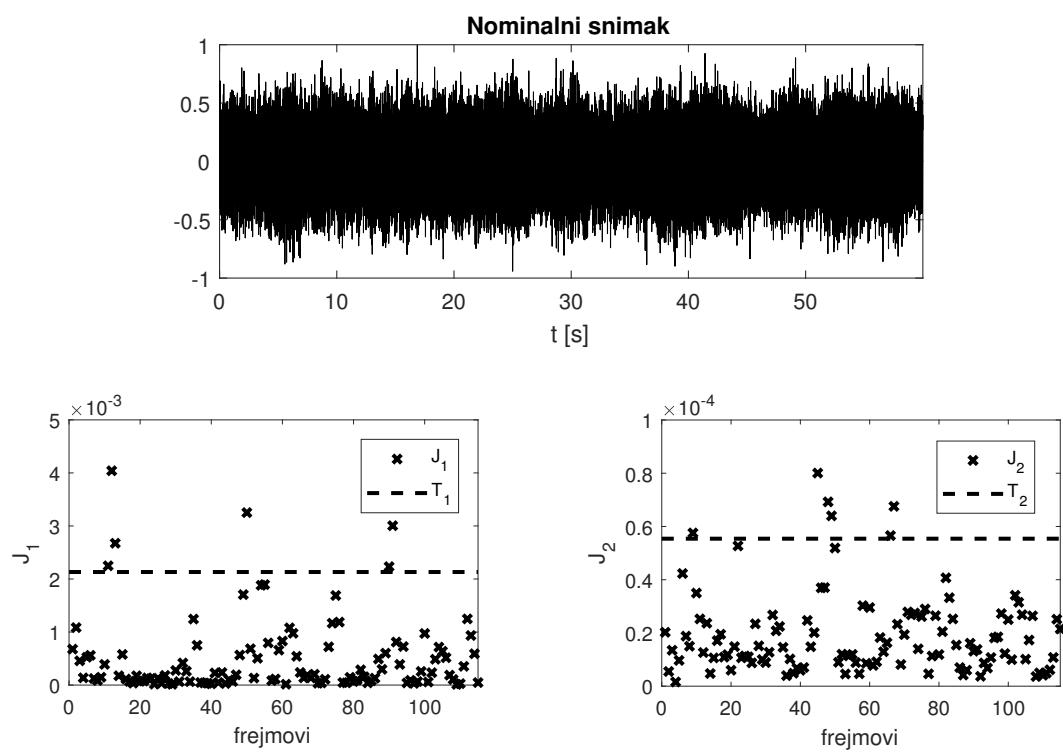
merenih odbiraka od linije koja se nalazi pod uglom od 45° i formirana je tačkama QQ_{nom} : (q_i, x_i^{nom}) . Na sličan način se može proceniti J_2 kao odstupanje tačaka na QQ krivoj od linije koja najbliže odgovara datom izmerenom segmentu QQ_{maes} : (q_i, x_i^{maes}) . Na slici 3.6 se može videti izgled jednog segmenta nominalnog snimka u odnosu na linije QQ_{nom} i QQ_{maes} .

Analizirajući sve segmente celokupnog nominalnog snimka koji traje 1 min moguće je odrediti granice T_1 i T_2 . Izgled nominalnog snimka u vremenskom domenu, kao i pozicija ovih granica u odnosu na skup srednje kvadratnih grešaka može se videti na slici 3.7. Ovim je procedura obučavanja završena i može da se pređe na monitoring signala.

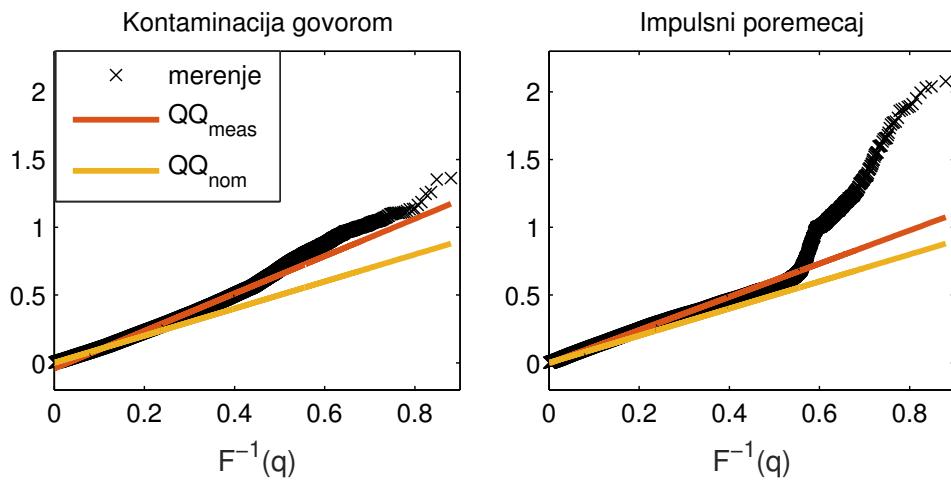
U procesu monitoringa prolazi se kroz segmente snimljenog signala i veličine J_1 i, ako je potrebno, J_2 se porede sa granicama kao u jednačini 3.15. Izgled QQ krive za različite vrste kontaminacije može se videti na slici 3.8. Jasno je da se oblik QQ krive značajno menja u zavisnosti od prisustva različitog tipa šuma. Na slici 3.9 je pokazano kako se algoritam ponaša na jednom izuzetno kratkom segmentu eksperimentalnog snimka. Na gornjem delu slike prikazan je deo testirajućeg signala u vremenskom domenu u kojem je obuhvaćen nominalni režim (crno), impulsni šum (crveno) i kontaminacija govorom (zeleno). Na donjem delu slike može se videti rezultat algoritma R za svaki segment.



Slika 3.6: Nominalni segment u odnosu na QQ_{nom} i QQ_{maes} .



Slika 3.7: Nominalni snimak (gore), kriterijum J_1 sa granicom T_1 (levo) i kriterijum J_2 sa granicom T_2 (desno).



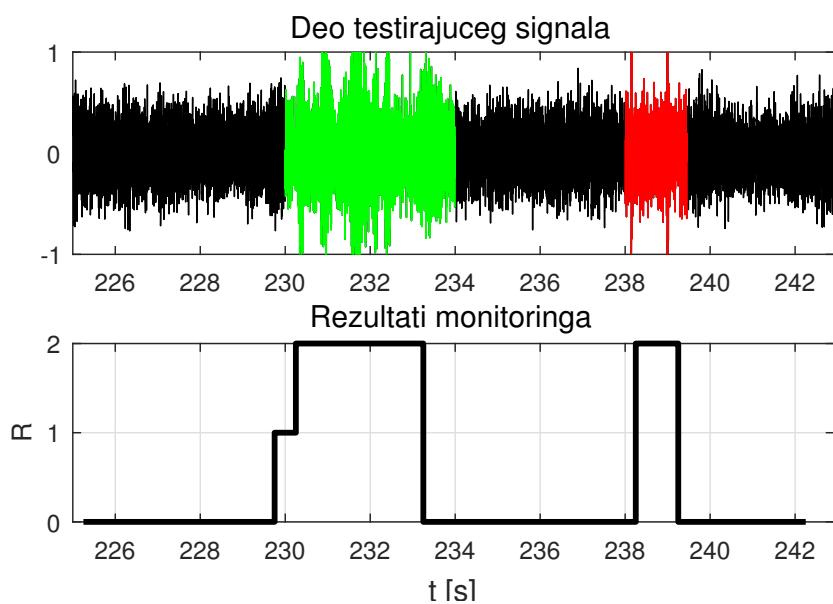
Slika 3.8: *QQ kriva segmenta koji je kontaminiran govorom (levo) i segmenta koji sadrži impulsni šum (desno).*

Tabela 3.1: *Rezultati detekcije kontaminacije.*

%	$R = 0$	$R = 1$	$R = 2$
Nominalni signal	97	3	0
Impulsni šum	9	5	86
Kontaminacija govorom	37	7	56
Pomeranje mikrofona	8	92	0

Jasno je da je kontaminaciju govorom teže detektovati nego impulsni poremećaj zbog manje jačine signala govora i mogućih promena u dinamici govora.

Rezultate testiranja algoritma na celokupnom snimku dužine 18 minuta nije praktično grafički predstaviti, tako da su prikazani u tabeli 3.1. Nominalni snimci se u 97% slučajeva klasifikuju kao nominalni, dok se pogrešna klasifikacija dešava samo u pravcu promene nominalnog režima. Impulsni poremećaj je klasifikovan kao kontaminacija u 86% slučajeva, dok govor ima značajno manji procenat tačne klasifikacije. Ovo može da bude zbog činjenice da se u toku govora menja jačina govornog signala i prave se pauze, tako da je prilično realno da samo 56% vremena govor zaista pravi primetnu kontaminaciju. Zanimljiva osobina algoritma je način na koji se ponaša na pomeranje mikrofona. Ovaj događaj se ne detektuje kao kontaminacija, ali u 92% slučajeva se posmatra kao promena nominalnog stanja. To znači da će algoritam predložiti ponavljanje procedure obučavanja svaki put kada se pozicija mikrofona promeni i na taj način se dokazuje adaptivnost algoritma na promene u nominalnom režimu.



Slika 3.9: *Deo testirajućeg snimka u vremenskom domenu (gore) i rezultat izvršavanja algoritma (dole).*

3.3 Klasifikacija kontaminacije

Motivacija za razvijanje algoritama za detekciju kontaminacije je jasna - sprečavanje kontaminiranih signala da dopru do algoritama za estimaciju stanja je izuzetno značajno za robustifikaciju tih algoritama i povećanje primenjivosti zvučnih signala u industriji. Sa druge strane, dobro je imati u vidu da ono što se za potrebe estimacije stanja naziva kontaminacija nije ništa drugo nego dodatna informacija o još nekom događaju koji se desio u blizini snimane lokacije. Razvojem oblasti ambijentalne analize i analize scenarija korišćenjem akustičkih signala otvara se prostor za proširenje problematike detekcije kontaminacije na istovremenu klasifikaciju detektovanih šumova. To se može koristiti za integraciju ne samo u sistem prediktivnog održavanja, već i praćenja dešavanja u postrojenju.

U nastavku biće predložene dve metode za klasifikaciju signala. Jedna ima standardni pristup testiranja hipoteza i koristi Neyman-Pearson test da detektuje kontaminaciju i razdvaja dve vrste šuma [98, 99], dok druga koristi metode često primenjivane u analizama scenarija, preciznije Mel-kestralne koeficijente i metodu nosećih vektora da klasifikuje proizvoljan broj vrsta kontaminacija [100].

3.3.1 Algoritam baziran na Neyman-Pearson testu

Testiranje hipoteza obuhvata familiju algoritama za prepoznavanje oblika koja podrazumeva poznavanje funkcija gustina verovatnoća klase koje se testiraju. Ovo je izuzetno zahtevan uslov jer je često veoma komplikovano proceniti statističku raspodelu svake klase. S obzirom da je u prethodnoj celini ovog poglavlja uspešno procenjena empirijska funkcija raspodele, logičan korak je pokušaj implementacije neke vrste algoritma za testiranje hipoteza u cilju klasifikacije kontaminacije. U okviru ovog algoritma koristiće se Neyman-Pearson test hipoteza za kreiranje diskriminacione linije i, u zavisnosti od toga gde se odbirci na QQ krivoj nalaze u odnosu na te linije, donosi se zaključak o klasi kojoj snimak pripada. Prvo će se izračunati diskriminaciona linija za detekciju kontaminacije, a onda će se izračunati i prag za klasifikaciju.

Neyman-Pearson test

Prilikom kreiranja klasifikatora dva kriterijuma moraju da se uzmu u obzir. U slučaju detekcije kontaminacije, prvi cilj je maksimizacija verovatnoće da će nekontaminirani snimci biti klasifikovani kao nominalni. Drugi cilj je minimizacija verovatnoće da će se zašumljeni snimci klasifikovati kao nominalni. Jedan način da se reši ovaj problem

je Neyman-Pearson metod za testiranje hipoteza [101, 102]. On podrazumeva fiksiranje verovatnoće p koja određuje željenu efikasnost u nominalnim uslovima. U literaturi se uglavnom usvaja ova vrednost u intervalu između 0.9 i 0.99, a u predloženom algoritmu fiksiraće se vrednost $p = 0.95$. Dakle, potrebno je odabrati α_i i β_i tako da se zadovolji uslov [96]

$$\int_{\alpha_i}^{\beta_i} f(x_i|i) dx_i = F(\beta_i|i) - F(\alpha_i|i) = p. \quad (3.16)$$

Ovde je $f(x_i|i)$ uslovna funkcija gustine verovatnoće odbirka x_i , ako se zna rang i u sortiranoj sekvenci $\{x_i\}$, $i = 1, \dots, N$. Ona se korišćenjem Bajesove formule može izračunati kao

$$f(x_i|i) = \frac{P(i|x_i) f_n(x_i)}{P(j)}, \quad (3.17)$$

gde je $f_n(\cdot)$ funkcija gustine verovatnoće sa nultom srednjom vrednošću i jediničnom varijansom, $P(i) = 1/N$, a $P(i|x_i)$ može da se dobije iz jednačine 3.1.

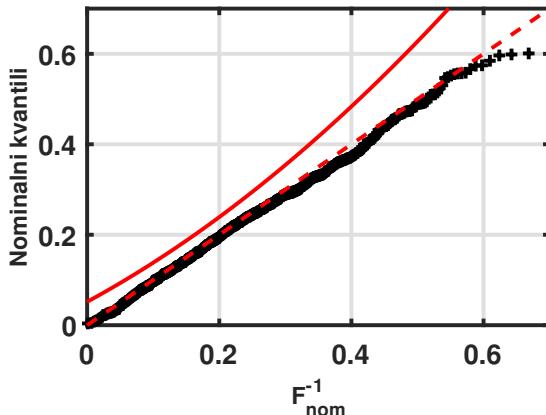
Postavka problema je ista kao u poglavlju 3.2, tako da postoje dve vrste kontaminacija i posmatra se QQ kriva u odnosu na anvelopu dobijenu Hilbertovom transformacijom. S obzirom da je anvelopa uvek pozitivna, očekuje se da će prisustvo kontaminacije povećati srednju vrednost signala koji se posmatra, tako će kontaminiran signal na QQ krivoj moći da se prepozna pomeranjem tačaka na gore u odnosu na $x = y$ liniju, odnosno kreiraće se ugao veći od 45° . Uz ovu prepostavku jednačina 3.16 može da se relaksira i, umesto traženja donje i gornje granice, može da se traži samo gornja granica za klasifikaciju kao

$$\int_0^{\alpha_i} f(x_i|i) dx_i = p. \quad (3.18)$$

U nastavku će se ovaj algoritam prvo testirati po pitanju sposobnosti da detektuje šum, a onda i po performansama klasifikacije.

Rezultati

Procena funkcije gustine verovatnoće i diskriminacione granice se vrši samo na početku. Posle tog koraka dovoljno je skicirati QQ krivu svakog segmenta i gledati u kom intervalu se nalaze odbirci. Prvo se testira sposobnost algoritma da detektuje kontaminaciju tako da se granica računa u odnosu na funkciju gustine verovatnoće nominalnih snimaka. QQ kriva nominalnog snimka sa tako dobijenom diskriminacionom linijom može se videti na slici 3.10. Kao što je i očekivano, sve tačke na grafiku se nalaze ispod diskriminacione krive, dakle segment je klasifikovan kao nezašumljen. Za testiranje detekcije kontaminacije koristi se segment snimka već prikazan na slici 3.9 (gore), dakle sadrži nominalne odbirke, kontaminiranost impulsnim šumom i govorom.

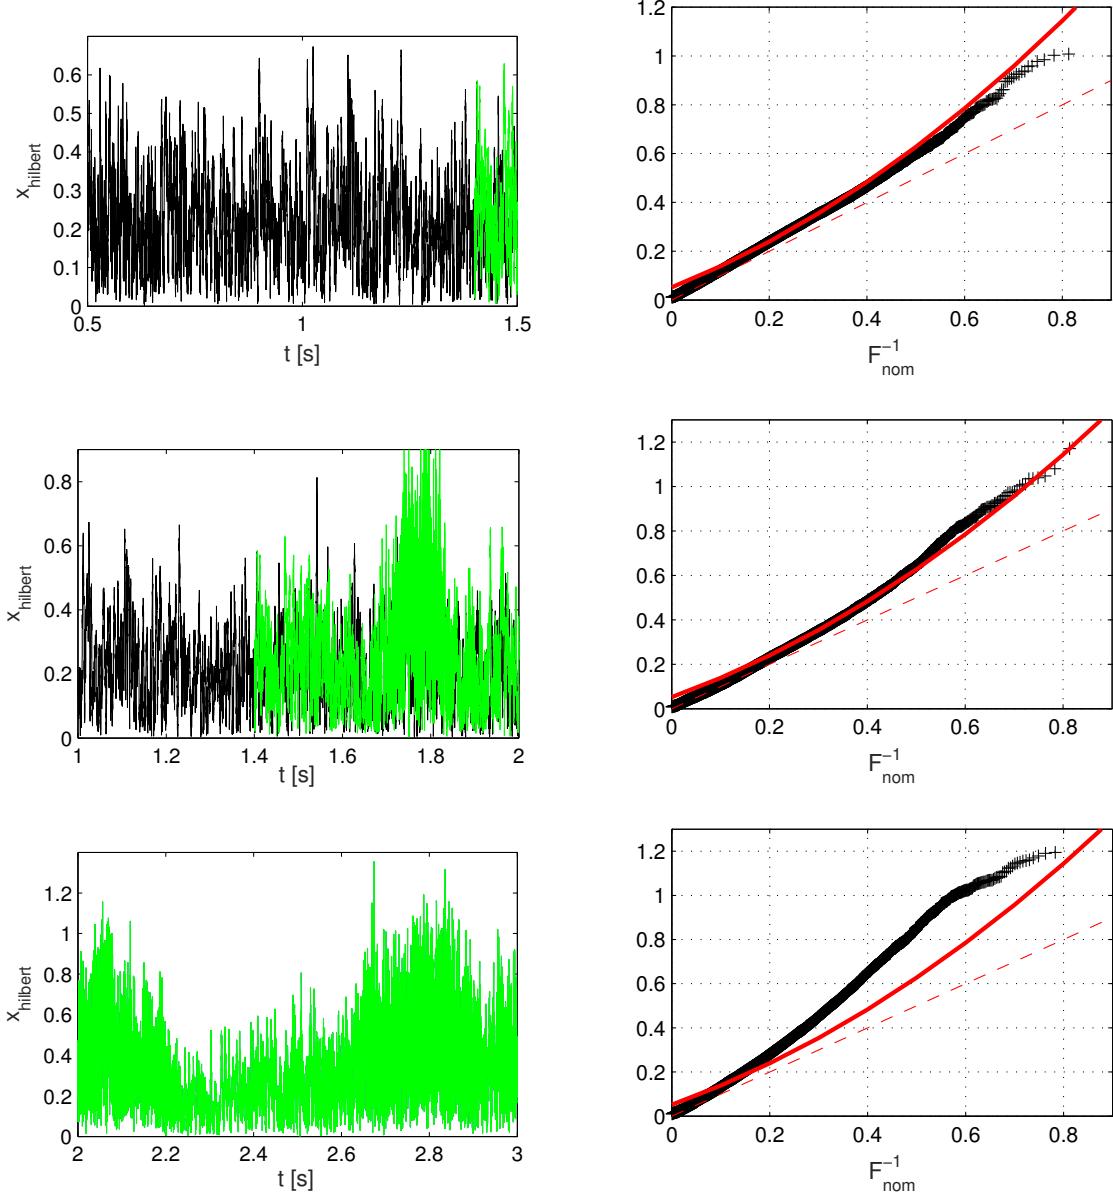


Slika 3.10: *QQ kriva nominalnog snimka sa diskriminacionom granicom α .*

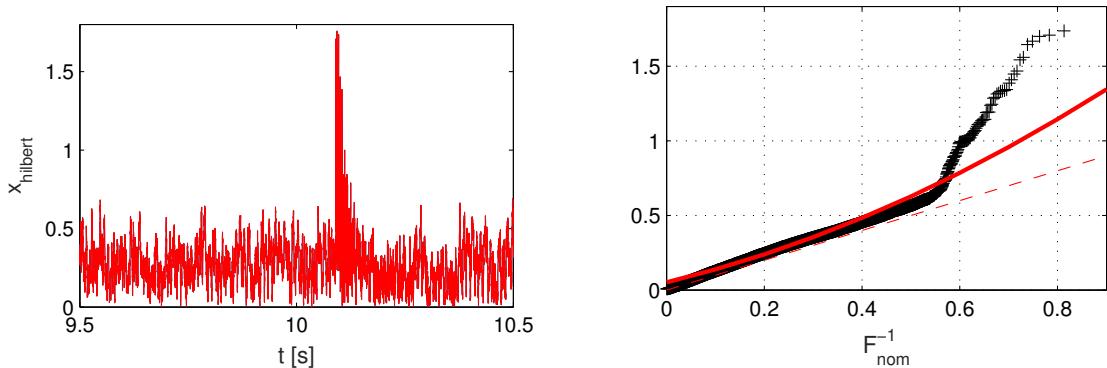
Slučajevi kada segment koji se testira sadrži samo govornu kontaminaciju prikazani su na slici 3.11. Levo se nalaze predstave anvelope signala u vremenskom domenu, a desno su odgovarajuće QQ krive. Efekat kontaminacije govorom na QQ krivu direktno zavisi od procenta kontaminiranog signala koji je obuhvaćen analiziranim segmentom. U slučaju kada se u izdvojenom segmentu nalazi samo signal koji je kontaminiran govorom, kao na slici 3.11 (dole), odgovarajuća QQ kriva ima kvantile koji leže na približno pravoj liniji, ali pod uglom većim od 45° u odnosu na x osu. Ovo ukazuje na to da je varijansa snimljenog signala, kao i srednja vrednost, veća nego što je očekivano. Takođe, većina odbiraka se nalazi iznad diskriminacione linije što znači da je algoritam detektovao kontaminaciju. Situacija nije toliko jasna kada je samo deo analiziranog segmenta kontaminiran govorom (slika 3.11 sredina). U tom slučaju ugao pod kojim se prostiru tačke na QQ krivoj je manji i, u zavisnosti od količine govora koji je obuhvaćen analiziranim segmentom, može da se desi da tačke ne pređu iznad diskriminacione linije. To znači da kontaminacija nije detektovana, kao na slici 3.11 (gore).

Kod impulsnog poremećaja problem je mnogo jednostavniji i algoritam uspeva da detektuje kontaminaciju bez obzira na količinu kontaminiranih odbiraka u segmentu. Razlog za to je u činjenici da je priroda impulsnog poremećaja toliko nagla da je čak i mali broj odbiraka u prozoru dovoljan da osetno poremeti statistiku signala. Odgovarajuća QQ kriva je prikazana na slici 3.12.

Iz dosadašnje analize je jasno da se dve vrste kontaminacije ponašaju značajno drugačije na QQ krivoj, tako da je moguće uvesti još jednu diskriminacionu liniju, β koja će da služi za klasifikaciju tipa kontaminacije. S obzirom da se po pravilu odbirci koji su kontaminirani impulsnim šumom nalaze iznad odbiraka kontaminiranih govorom na QQ krivoj, druga diskriminaciona linija se računa preko relacije 3.18, samo se umesto ras-



Slika 3.11: Snimci kontaminirani govorom (levo) i odgovarajuća QQ kriva (desno).



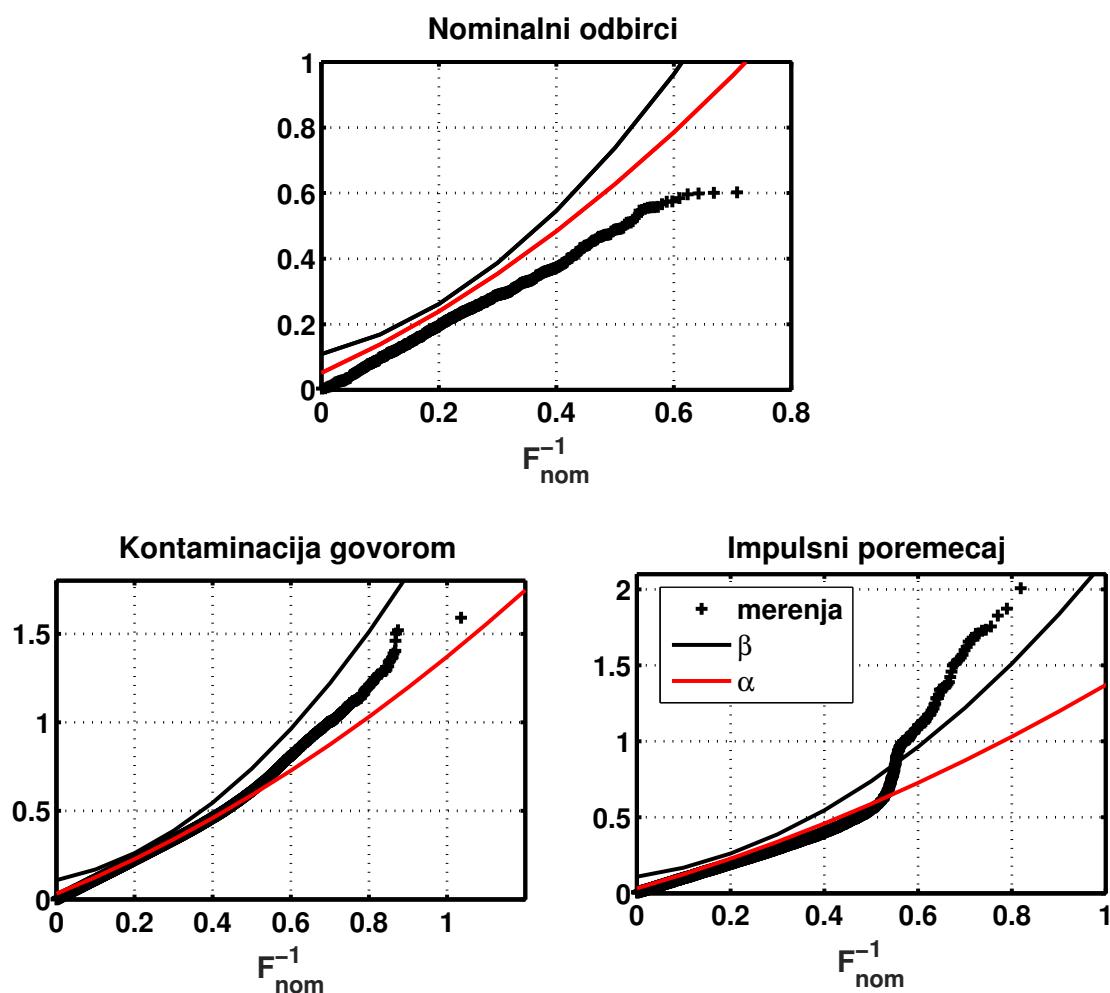
Slika 3.12: Snimci kontaminirani impulsnim šumom (levo) i odgovarajuća QQ kriva (desno).

podele nominalnog signala sada koristi raspodela signala kontaminiranog govorom koja je estimirana na isti način. Ovako se dobiju dve klasifikacione linije, jedna razdvaja nominalne odbirke od kontaminiranih, a druga određuje da li je u pitanju kontaminacija govorom ili impulsna kontaminacija. U slučaju kada nema kontaminacije očekuje se da će svi odbirci na QQ krivoj da se nalaze ispod obe klasifikacione linije (slika 3.13 gore). Ako se, sa druge strane, javi kontaminacija govorim signalom očekuje se da svi odbirci budu ispod druge klasifikacione krive, β , ali da neki svakako prelaze preko α , kao na slici 3.13 (levo). Najzad, ako se javi impulsni šum prepostavlja se da će postojati odbirci na QQ krivoj koji se nalaze iznad obe klasifikacione linije (slika 3.13 desno).

Rezultati klasifikacije primenom Neyman-Pearson metode mogu se videti u tabeli 3.2. Iz uspešnosti klasifikacije impulsnog šuma može se primetiti da je izuzetno rigorozan kad su u pitanju nagle promene vrednosti signala, međutim tačna klasifikacija govornog signala se dešava samo u 55% slučajeva. To je zbog činjenice da se statistički parametri segmenta koji se posmatra ne menjaju značajno u odnosu na nominalni režim kada je samo mali deo segmenta kontaminiran govorom. Iako se metode statističkog testiranja hipoteza veoma često koriste, glavni nedostatak u ovom slučaju je potreba da se detaljno analiziraju statistike svih klasa radi uspešne klasifikacije. Na primeru realnog problema klasifikacije zvukova u industrijskom postrojenju očekuje se veliki broj mogućih vrsta kontaminacija, tako da korišćenje ovih metoda nije preporučljivo.

3.3.2 Algoritam baziran na metodi nosećih vektora

Metoda nosećih vektora (engl. *Support Vector Machine*, SVM) je izuzetno često korišćena zadnjih nekoliko godina, a posebno uspešne rezultate daje u oblasti klasifikacije



Slika 3.13: *QQ kriva sa dve klasifikacione linije.*

Tabela 3.2: *Klasifikacija kontaminacije Neyman-Pearson testom.*

%	Nominalni signal	Impulsni šum	Kontaminacija govorom
Nominalni signal	97	2	1
Impulsni šum	0	100	0
Kontaminacija govorom	20	25	55

audio signala [103]. U predloženom algoritmu će se koristiti za potrebe detekcije i klasifikacije. Za razliku od većine drugih klasifikatora, SVM ne vrši estimaciju uslovnih gustina raspodele, već kreira granice u multi-dimenzionom prostoru, tako da zahteva manje podataka za obavljanje klasifikacije. Jedna velika prednost ove vrste klasifikatora je u tome što ne podležu prokletstvu dimenzionalnosti kao mnoge druge metode koje se oslanjaju na procene statističkih raspodela. S obzirom da je SVM binarni klasifikator, predložena je strategija za proširenje na problem više klase koristeći modifikovanu stablastu strukturu [104], kako bi se obezbedilo izvršavanje detekcije i klasifikacije.

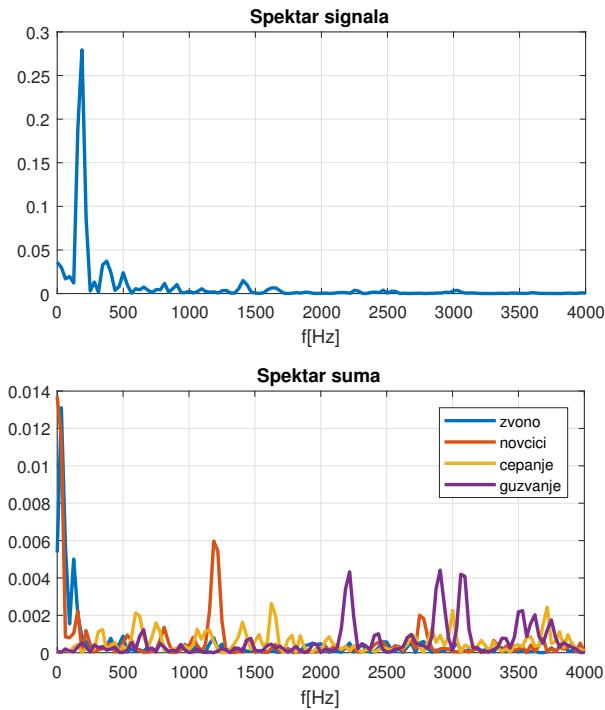
Eksperimentalna postavka

Za potrebe razvijanja i testiranja ovog algoritma koristi se nominalni signal snimljen u okolini ventilatorskog mlina iz poglavlja 2.4. Međutim, što se kontaminacija tiče, cilj je da se predloži struktura koja je sposobna da razdvoji više tipova šuma. S tim u vidu prethodna eksperimentalna postavka u kojoj postoje samo dve vrste kontaminacije nije dovoljna. Ovaj problem je prevaziđen na sledeći način: prvo je snimljen nominalni signal u okolini mlina kada ne postoje eksterne vrste kontaminacija, pa je zatim taj signal veštački zagađen jednom od 4 vrste šuma koji su zasebno snimani u akustički izolovanom prostoru. Postoji jako malo akustičkih baza koje su dostupne javnosti i imaju dovoljno bogat assortiman zvukova, tako da je izbor različitih šumova bio veoma ograničen. Četiri vrste kontaminacija su izabrane: zvuk zvona, zvuk novčića koji se mešaju, zvuk gužvanja i zvuk cepanja papira i ovi signali su preuzeti iz RWCP (engl. *Real World Computing Partnership*) akustičke baze podataka [105].

Cilj ove eksperimentalne postavke je da se detektuje da li je dato merenje kontamirano i, ako jeste, koja od 4 vrste kontaminacije je u pitanju. S obzirom da je veštački uveden šum, moguće je testirati ovaj algoritam za različite vrednosti odnosa signal-šum (engl. *Signal-to-Noise Ratio*, SNR). Izgled nominalnog signala i šumova u frekvencijском domenu može se videti na slici 3.14. Frekvencijska karakteristika ukazuje na to da ovi signali imaju različitu raspodelu u frekvencijskom domenu; međutim, ove razlike mogu da budu manje ili više izražene u zavisnosti od odnosa signal-šum (što je SNR veći manje su izražene komponente šuma).

Izdvajanje obeležja

Radi smanjenja računske kompleksnosti svi signali su filtrirani i decimacijom im je smanjena frekvencija odabiranja sa 48 kHz na 8 kHz. Zatim su podeljeni na segmente veličine 128 odbiraka, sa preklapanjem od 50% između njih. Dalje, nominalni snimci

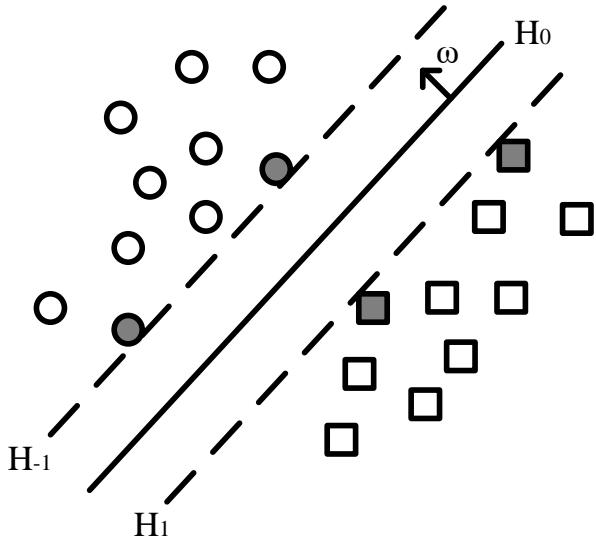


Slika 3.14: *Nominalni signal (gore) i 4 vrste šuma (dole) u frekvencijskom domenu.*

sa mlina su podeljeni u 5 delova. Jedan deo se koristi u svojoj originalnoj formi kao primer nezašumljenog signala, a ostali delovi su kontaminirani, svaki sa drugačijom vrstom šuma. Obeležja koja se posmatraju u ovom algoritmu su često korišćena u obradi i prepoznavanju govora i muzike [106], a to su 14 mel-kestralnih koeficijenata dobijenih korišćenjem 20 mel-skaliranih spektralnih opsega . U skup obeležja dodata je i energija segmenta kao petnaesti parametar. Zbog male količine signala šuma u RWCP akustičkoj bazi postoji samo 111 segmenata koji su kontaminirani sa svakom vrstom šuma i 444 segmenata koji nisu kontaminirani.

Metoda nosećih vektora

Metoda nosećih vektora (SVM) je algoritam za prepoznavanje oblika koji koristi n -dimenzionalne vektore $x_i \in \mathbb{R}^n$ dve separabilne klase da konstruiše hiperravan, u formi $\omega \cdot x + b = 0$, koja za cilj ima razdvajanje dve klase obučavajućih podataka [107]. U ovoj postavci ω predstavlja vektor normalan na hiperravan H_0 , a b određuje pomeranje H_0 u odnosu na koordinatni početak, kao na slici 3.15. Cilj je da se nađe klasifikaciona hiperravan H_0 koja maksimizuje udaljenost od najbližih tačaka svake klase. Dakle, izbor H_0 zavisi samo od tačaka x_i koje su najbliže paralelnim hiperravnima H_1 i H_{-1} . Te tačke se nazivaju noseći vektori i označeni su na slici sivom bojom.



Slika 3.15: Klasifikacija koristeći optimalnu klasifikacionu hiperravan H_0 i granične hiperravni H_1 i H_{-1} .

Ako postoji obučavajući skup od m tačaka $X = \{x_1, \dots, x_m\}$, gde $x_i \in \mathbb{R}^n$, $i = 1, \dots, m$ i odgovarajući skup klasa $Y = \{y_1, \dots, y_m\}$, gde $y_i \in \{1, -1\}$, nalaženje klasifikacione hiperravni može da se formuliše kao optimizacioni problem:

$$\min \frac{1}{2} \|\omega\|^2, \quad (3.19)$$

tako da $y_i(\omega x_i + b) \geq 1$.

Ovaj problem se rešava određivanjem sedlaste tačke Lagranžovog funkcionala pomoću numeričke matematike kao:

$$L(\omega, b, \alpha) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^m \alpha_i [y_i f(x_i) - 1]. \quad (3.20)$$

U svojoj originalnoj postavci SVM se koristi za problem binarne klasifikacije linearno separabilnih klasa. S obzirom da se jako retko susreću linearно separabilni problemi u prepoznavanju oblika, ova ograničenja su prevaziđena određenim vrstama relaksacija. Naime, za neseparabilne klase problem maksimizacije distance se relaksira tako što se uvodi marga pomoću koje se postavi uslov za razdvajanje mnogih, ali ne obavezno svih tačaka obučavajućih skupova. Dakle, kada klase nisu separabilne, uvodi se relaksirajuća promenljiva $\xi_i \geq 0$ koja predstavlja meru pogrešne klasifikacije za svaki obučavajući

vektor. Ovo donekle modifikuje optimizacioni problem iz jednačine 3.19 na sledeći način:

$$\min \left(\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m \xi_i \right), \quad (3.21)$$

tako da $y_i (\omega x_i + b) \geq 1 - \xi_i$.

Ovde je C pozitivna konstanta koja kontroliše meru u kojoj se penalizuju relaksirajuće promenljive.

Osim linearne klasifikacije, SVM može dodatno da se modifikuje da vrši nelinearnu klasifikaciju. Ovaj problem se rešava mapiranjem podataka u prostor veće dimenzije u kojoj su klase linearно separabilne. Onda se na ovaj linearni problem primenjuju standardni SVM pristupi. Proces mapiranja odbiraka u više dimenzije se obavlja kernel funkcijama. Dve kernel funkcije koje se najčešće koriste su radikalna bazisna funkcija (RBF)

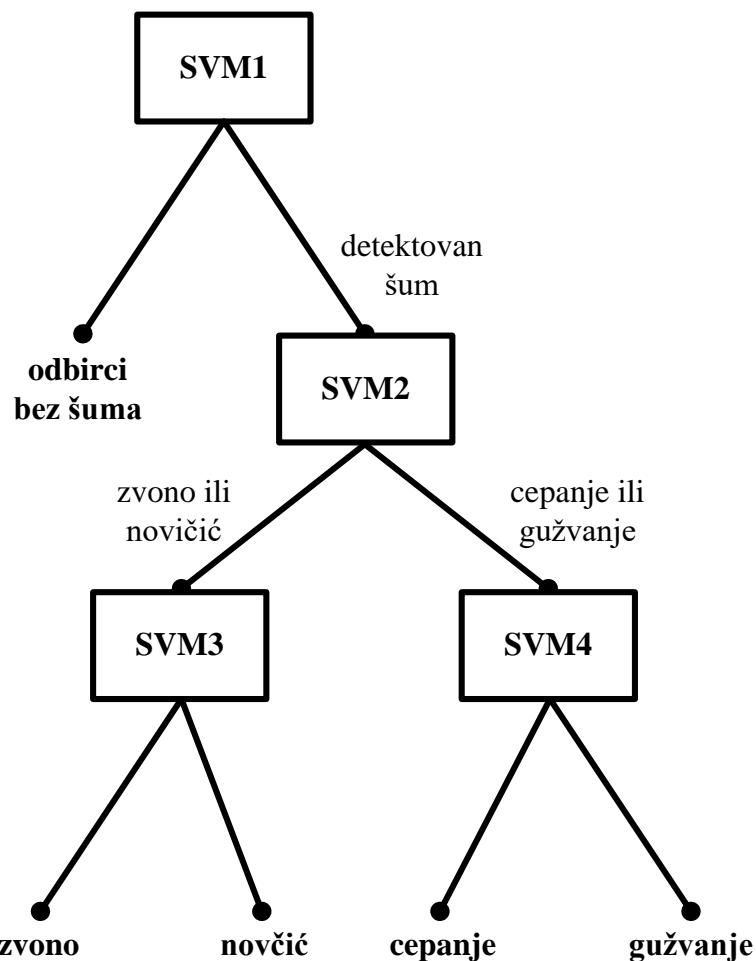
$$K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right) \quad (3.22)$$

i polinomska funkcija

$$K(x_i, x_j) = (x_i \cdot x_j)^a. \quad (3.23)$$

S obzirom da je SVM binarni klasifikator, potrebno je primeniti određene strategije kako bi mogao da se uspešno koristi za klasifikaciju više klasa. U literaturi su predložene razne metode; međutim najčešći je slučaj da se sama struktura klasifikatora koriguje za specifičnu primenu za koju se koristi. Najkorišćenija strategija je *jedan-protiv-svih* kod koje postoji onoliko klasifikatora koliko ima klasa, a i -ti klasifikator treba da napravi procenu da li analizirani vektor pripada i -toj klasi ili nekoj od ostalih. Još jedna izuzetno popularna strategija je *svi-protiv-svih* koja ima znatno više klasifikatora koji procenjuju između svake dve klase koja najviše odgovara vektoru. U ovom slučaju potrebna je i neka vrsta strategije glasanja da se proceni koja je na kraju strategija u pitanju.

U okviru algoritma predloženog ovde koristiće se jedna vrsta modifikacije binarnog stabla koja prvo vrši detekciju kontaminacija, pa tek ako kontaminacija postoji prelazi na stablastu strukturu čiji je zadatak klasifikacija. Predlog binarnog stabla može se videti na slici 3.16 i on koristi 4 klasifikatora da raspodeli odbirke u jednu od 5 različitih kategorija. Prvi SVM klasifikator testira da li postoji kontaminacija ili ne. Drugi SVM se koristi samo ako je kontaminacija detektovana i proverava da li kontaminaciju proizvodi metalni zvuk (zvono i novčići) ili papirni zvuk (gužvanje i cepanje). Na kraju treći, ili četvrti SVM se koristi da bi se odredilo koji je tačno izvor kontaminacije u pitanju. Ovom vrstom analize se značajno smanjio broj klasifikatora koji se proverava u svakom segmentu signala, s



Slika 3.16: *Binarno stablo za detekciju i klasifikaciju kontaminacije.*

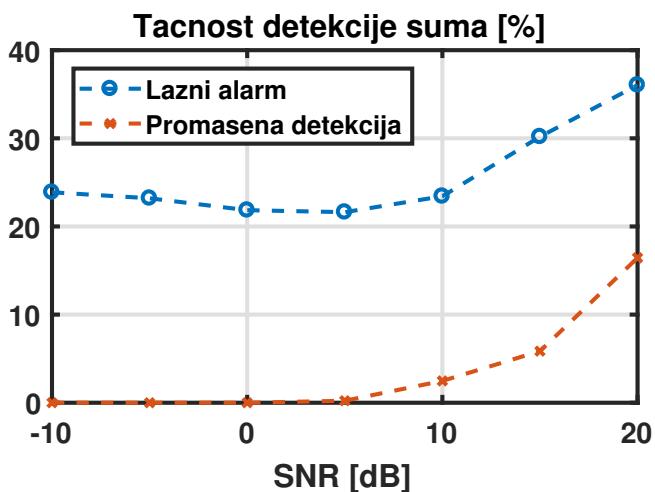
obzirom da se u slučaju kada nema šuma proverava rezultat samo jednog klasifikatora, a kada ima šuma proveravaju se tri.

Rezultati

Za testiranje rezultata klasifikacije prvo je neophodno obučiti 4 SVM klasifikatora. Prvi SVM služi za detekciju kontaminacije i na raspolaganju za njegovo obučavanje i testiranje imamo 888 segmenata zvučnog signala. Od njih je 444 nezašumljeno, a od ostalih 444 ima podjednak broj segmenata koji su kontaminirani svakim od 4 različita šuma. Jedna trećina svih segmenata je korišćena za obučavanje, a dve trećine za testiranje SVM1. Rezultati detekcije kontaminacije za odnos signal-šum SNR=10 dB prikazan je u tabeli 3.3 u formi matrice konfuzije. Broj lažnih alarma (segmenata koji nisu zagađeni šumom, ali su klasifikovani kao kontaminirani) je veoma visok - čak 23%. Međutim, s obzirom da je glavni razlog za implementaciju ove vrste algoritma povaćanje robusnosti metoda prediktivnog održavanja koji koriste signale zvuka, ovaj visok procenat lažnih

Tabela 3.3: Metoda nosećih vektora - rezultati detekcije za SNR=10 dB.

%	Klasifikovan kao nekontaminiran	Klasifikovan kao kontaminiran
Nekontaminirani odbirci	77	23
Kontaminirani odbirci	2	98



Slika 3.17: Stopa lažnih alarma i promašene detekcije kao funkcija SNR.

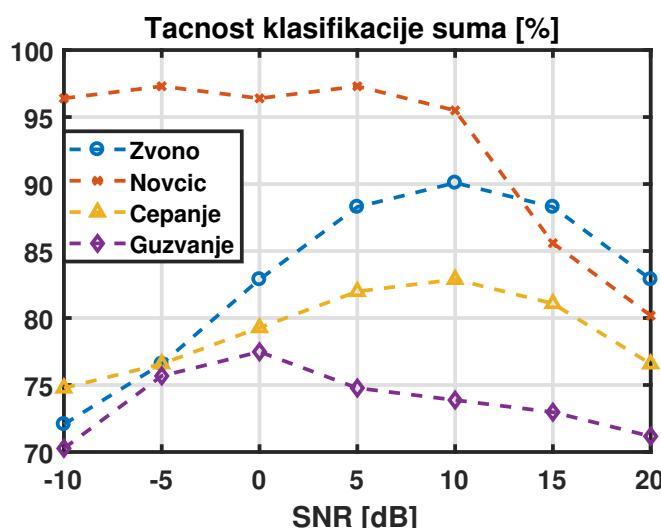
alarmi može da se toleriše dokle god se kontaminirani segmenti zaista klasificuju kao kontaminirani. Iz tabele se vidi da ovo jeste slučaj, jer se u samo 2% slučajeva dešava promašena detekcija. Ovi rezultati ukazuju na to da je predloženi algoritam izuzetno rigorozan prema kontaminiranim segmentima.

Na slici 3.17 mogu se videti promene količine lažnih alarma i promašene detekcije kako SNR raste. Za niske vrednosti SNR, šum je veoma izražen i mnogo je lakše detektovati ga. Dokle god je SNR manji od 5 dB stopa detekcije kontaminacije je 100%, doduše po cenu velikog broja lažnih alarma. Kada SNR dostigne vrednost veću od 20 dB, stopa lažnih alarma i promašene detekcije postaje jako velika što ukazuje na to da šum nije značajno izražen i algoritam će imati poteškoće prilikom detekcije. Ni ovo nije problematično sa stanovišta robustifikacije estimatora stanja, jer nizak nivo šuma verovatno neće značajno uticati na informativan deo zvučnog signala.

Drugi deo algoritma se odnosi na klasifikaciju kontaminacije i postoji 111 segmenata koji su kontaminirani sa po jednom od 4 vrste šuma. SVM2 služi za detekciju prirode šuma i ima na raspolaganju 444 segmenata za obučavanje i testiranje. Zbog malog broja

Tabela 3.4: Metoda nosećih vektora - rezultati klasifikacije za SNR=10 dB.

%	Zvono	Novčić	Cepanje	Gužvanje
Zvono	90	8	1	1
Novčić	0	95	0	5
Cepanje	1	10	83	6
Gužvanje	0	21	5	74



Slika 3.18: Tačnost klasifikacije kao funkcija SNR.

podataka, jedna polovina ovih segmenata je korišćena za obučavanje, a ostala polovina za testiranje. Sa druge strane SVM3 i SVM4 služe za razluče koji konkretan šum je u pitanju i oni imaju po 222 segmenta za obučavanje i testiranje. I u ovom slučaju segmenti su podeljeni na pola. Tabela 3.4 prikazuje matricu konfuzije kada je SNR=10 dB. Zvukovi zvona i novčića imaju najveću tačnost klasifikacije, a razlog za to može da leži u činjenici da papirni zvukovi imaju uniformnije raspodeljene frekvencijske komponente, pa ih je teže detektovati u izdvojenim obeležjima.

Tačnost klasifikacije za različite vrednosti SNR mogu se videti na slici 3.18. Ponovo zvukovi zvona i novčića imaju najveći procenat tačne klasifikacije za gotovo sve vrednosti SNR. Ono što se može primetiti je da je globalni trend detekcije kontaminacije takav da se tačnost smanjuje sa povećanjem odnosa signal-šum. To je očekivan rezultat ako se uzme u obzir da smanjenje intenziteta šuma podrazumeva i slabljenje razlike karakterističnih obeležja koji se koriste za klasifikaciju. Još jedna zanimljiva pojava je da se za male vrednosti signal-šum ne može detektovati neki distinktni trend ponašanja tačnosti

klasifikacije, odnosno gotovo sve klase imaju neočekivane periode rasta i opadanja tačnosti. Jedno moguće objašnjenje takvog ponašanja je nedovoljna informativnost izdvojenih obeležja. Na taj način može se zaključiti da obeležja koja su odlične rezultate davala u problemima detekcije ne moraju da budu podjednako informativna kada je reč o klasifikaciji.

Iako klasifikatori imaju tačnost veću od 70% za svaki klasifikator, moguće je poboljšati njihove performanse malim izmenama u algoritmu. Promena obeležja koja se koriste u klasifikaciji, sa ciljem pravljenja jedinstvenog skupa za svaki SVM, bi verovatno unapredila rezultate, ali bi detaljnija analiza svakog od binarnih klasifikatora bila neophodna. Ono što je dobra strana predložene metode je činjenica da nije potrebna velika količina podataka za obučavanje algoritma, a moguće je povećati količinu i vrstu šumova koji se klasifikuju jednostavnim dodavanjem čvorova u binarnom stablu. Naime, u literaturi se ovakve strukture koriste za uspešno prepoznavanje i po nekoliko desetina različitih klasa.

3.4 Kratak rezime

Tri nove metode za detekciju kontaminacija akustičkog signala su predložene u ovom poglavlju. Sve tri metode su testirane na signalima zvuka snimljenim u realnim industrijskim uslovima, u termoelektrani Kostolac A1.

Algoritam za adaptivnu detekciju kontaminacije koristi QQ krive kao jednostavan alat za poređenje očekivane raspodele signala i trenutne raspodele. Osim detekcije nestacionarnog šuma ovaj algoritam može i da detektuje promenu stanja nominalnog režima snimljenih signala. Dakle, njegova adaptivnost se ogleda u detekciji promene nominalnih karakteristika i ponavljanju procedure obučavanja svaki put kada se to desi, a efikasna detekcija kontaminacije obezbeđuje robustifikaciju algoritama za detekciju stanja koji bi koristili te zvučne signale.

U cilju proširenja primene algoritama za analizu scenarija i ambijentalnu analizu, predložena su dva algoritma za klasifikacije kontaminacije. Jedan predstavlja implementaciju Neyman-Pearson testa hipoteza na predstavu signala QQ krivama i testiran je na dve vrste kontaminacije. On uspeva da klasificiše impulsnu kontaminaciju sa jako velikom tačnošću, ali uspešnost klasifikacije kontaminacije u vidu govornog signala zavisi od procenta obuhvaćenosti same kontaminacije unutar analiziranog prozora. Drugi algoritam za klasifikaciju koristi Mel-kestralne koeficijente i metodu nosećih vektora. Testiran je na 4 vrste kontaminacije uz mogućnost jednostavnog proširenja na više različitih vrsta. Uspešnost klasifikacije je jako velika - preko 70% za sve vrste šuma, a za neke karakteristične zvukove je preko 90%.

Glava 4

Detekcija stanja rotacionih aktuatora

Rotacioni aktuatori kao što su ventili, pumpe, turbine, mlinovi, izuzetno su zastupljeni u industriji, a njihovo adekvatno funkcionisanje je od suštinskog značaja za mnoga industrijska postrojenja. Iz tog razloga oni često predstavljaju glavni cilj istraživanja u literaturi koja se bavi razvijanjem metoda za prediktivno održavanje. Postoje dva pristupa koja mogu da se primene prilikom razvijanja algoritama koji prate promenu ponašanja mašine. Jedan se odnosi na detekciju otkaza ili promene radnog režima, kada je dovoljno doneti diskretnu odluku o tome u kom stanju se posmatrani sistem trenutno nalazi. Drugi pristup se odnosi na kontinuirano praćenje promene stanja mašine i najčešće se koristi prilikom rešavanja problema praćenja nivoa istrošenosti nekih elemenata, i on je dosta ređe zastupljen u literaturi.

Osnovni pristup rešavanju problema detekcije stanja se svodi na odabir adekvatne metode za preprocesiranje signala, zatim izdvajanje relevantnih obeležja i najzad primenu metoda prepoznavanja oblika u cilju dijagnostike mašine. U ovom poglavlju biće opisani metodi za estimaciju stanja rotacionih aktuatora koristeći signale zvuka. Imajući u vidu detektore kontaminacija razvijane u prethodnom poglavlju, prepostavka je da će estimatori stanja uglavnom imati na raspolaganju merenja koja sadrže samo stacionarni šum. Dakle, cilj je da se implementira algoritam koji će, koristeći signale zvuka snimljene u realnom industrijskom okruženju, uspešno da detektuje stanje u kome se mašina nalazi.

Preprocesiranje se obavlja sa ciljem dobijanja vektora obeležja iz izmerenih signala. Postoje razne metode koje se koriste u ove svrhe i one su opisane u poglavlju 2.2. Dvodimenzionalni prikazi izmerenog signala u vidu vremensko-frekvencijskih transformacija su veoma informativni, međutim prilično kompleksni za izračunavanje i analizu jer se

moraju koristiti metode analize slike koje nije lako implementirati u realnom vremenu. Zbog toga je, u slučaju opravdane prepostavke linearnosti i stacionarnosti signala, često efikasnije koristiti jednostavnu analizu u vremenskom i frekvencijskom domenu ponasob.

Algoritmi za prepoznavanje oblika i klasifikaciju se primenjuju posle preprocesiranja. Oni služe da bi se iz vektora obeležja doneli odgovarajući zaključci o stanju mašine. Postoji pregršt algoritama klasifikacije koji su testirani i implementirani na realnim procesima, od kojih su najčešće korišćeni neuralne mreže [108], fazi logika [109] i genetski algoritmi [110]. Svi oni su pokazali da mogu da procesiraju izuzetno kompleksne podatke i uspešno daju procenu o otkazu u rotirajućim elementima. Međutim, često kada je u pitanju praćenje promene stanja mašina ili istrošenosti elemenata, podela na dve ili više klase nije primenjiva, već je potrebno imati neku kontinualnu metriku koja se polako menja sa vremenom, i u tom slučaju su standardne tehnike klasifikacije prilično teško primenjive.

U nastavku biće prvo opisana metoda predobrade akustičkih signala i izdvajanja obeležja. Ona će biti primenjena na signalima dobijenim sa ventilatorskog mlina, ali se postupak može jednostavno generalizovati za bilo koju vrstu rotacionih aktuatora. Posle toga biće opisan novi algoritam za klasifikaciju stanja korišćenjem Bajesovih mreža [111]. Ovo je prilično moćan alat koji je sposoban da modelira ponašanje izuzetno složenih procesa, a u okviru problema estimacije stanja biće predložena nova struktura za detekciju stanja, uz razmatranje usložnjavanja te strukture u cilju rešavanja kompleksnijih problema. Najzad, biće predložene dve metode, jednostavne za implementaciju na nekom hardverskom uređaju, koje vrše kontinualnu procenu promene stanja mašine koristeći algoritme prepoznavanja oblika [112].

4.1 Izdvajanje obeležja i analiza diskriminante

U cilju očuvanja jednostavnosti izračunavanja, pa samim tim i omogućenja proširenja primene predloženih algoritama za implementaciju na jednostavnim hardverskim mikrokontrolerskim uređajima, koristi se metoda analize signala u vremenskom i frekvencijском domenu. Ovakva analiza može da se implementira samo ako je prepostavka o stacionarnosti signala na primeru zvuka rotirajućih aktuatora opravdana.

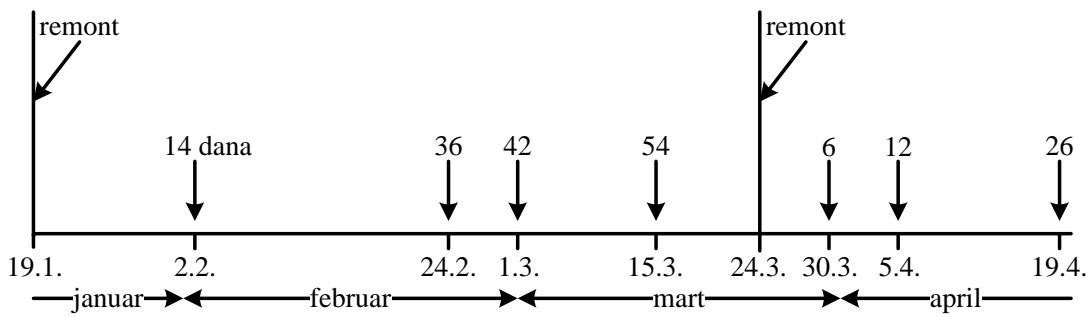
Sa jedne strane u pitanju jeste ciklostacionaran proces, tako da se karakteristike zvuka periodično ponavljaju. Dakle, dokle god je analizirana vremenska sekvenca značajno veća od periode rotacije maštine, može da se smatra da je prepostavka o stacionarnosti ispunjena. Dalje, povećanjem istrošenosti komponenti dolazi do promene vibracija koje se stvaraju, pa samim tim i do promene akustičkog potpisa maštine. Međutim, ova promena je suviše spora da bi pravila značajan uticaj na sekvencu snimljenog signala. Najzad, postoji opasnost od nestacionarnih elemenata u vidu naglih kontaminacija, ali taj problem je prevaziđen prethodnom implementacijom algoritma za detekciju kontaminacije. Uvezši sve to u obzir može da se zaključi da dvodimenzionalna analiza signala zaista nije neophodna i da sve relevantne informacije mogu da se dobiju iz zasebnih vremenskih i frekvencijskih prikaza.

4.1.1 Akvizicija signala

U cilju obučavanja i testiranja algoritama za estimaciju stanja koji će biti opisani u ovom poglavlju neophodno je napraviti dovoljno bogatu i dovoljno informativnu bazu akustičkih snimaka u svim stadijumima istrošenosti udarnih ploča mlina. S tim u vidu vršena su snimanja u periodu od četiri meseca u proseku jednom na svake dve nedelje. Datumi snimljenih zvučnih signala mogu se videti na slici 4.1. Svaka sesija snimanja je trajala 20 minuta i, radi obogaćenja baze za testiranje i obučavanje, ovi snimci su podeljeni na kraće segmente trajanja 60 s, sa preklapanjem od 75%. U toku ovog perioda obuhvaćena su dva remonta mlina (odnosno dva puta je menjano radno kolo), tako da su prikupljeni podaci reprezentativni za sve stadijume istrošenosti udarnih ploča mlina.

4.1.2 Izdvajanje obeležja

Za karakterizaciju snimljenog zvučnog signala potrebno je izdvojiti specifična obeležja kako bi se na osnovu njih donela procena o stanju maštine. Najčešće nije poznato na koji tačno način promena stanja maštine utiče na signal koji se snima, tako da nije ni uvek jasno koja obeležja treba izdvojiti u cilju detekcije. Ako se usvoji suviše mali broj



Slika 4.1: *Termini snimljenih zvučnih signala i broj radnih dana mlina od poslednjeg remonta za svaku sesiju snimanja.*

obeležja, postoji mogućnost da se ne dobiju sve informacije neophodne za tačnu procenu. Sa druge strane, preveliki broj obeležja je problematičan zbog povećanja računske kompleksnosti algoritma, a da pritom ne postoje garancije o povećanoj tačnosti detekcije. Osim toga, sa povećanjem broja obeležja često se dolazi u paradoksalnu situaciju da je sve teže dobiti tačnu procenu. Ovo se zove „prokletstvo dimenzionalnosti“ (engl. *curse of dimensionality*) i njemu podleže većina algoritama za prepoznavanje oblika. Prokletstvo dimenzionalnosti podrazumeva da se broj potrebnih podataka za obučavanje algoritma eksponencijalno povećava kako broj obeležja raste.

Visoka dimenzionalnost vektora obeležja može da se prevaziđe na više načina: neki algoritmi obavljaju optimalnu selekciju obeležja iz originalnog multidimenzionalnog skupa, neki primenjuju procedure redukcije dimenzija u kojoj redukovana obeležja predstavljaju kombinaciju svih originalnih dimenzija, a neki algoritmi koriste kros-validaciju da bi izbegli preobučavanje koje se često dešava kada je broj dimenzija preveliki u odnosu na broj merenih podataka. U predloženim algoritmima u okviru ovog poglavlja problem potencijalne prevelike dimenzionalnosti je rešen uvođenjem linearne redukcije dimenzija koja ne samo da smanjuje dimenzionalnost problema, već i ukazuje na relevantnost pojedinih obeležja u okviru algoritma.

U cilju izdvajanja obeležja posmatra se Hilbertova transformacija signala, odnosno anvelopa signala u vremenskom i frekvencijskom domenu. Obeležja koja se koriste su osnovne statističke osobine signala u vremenu i vrednost spektralne gustine snage na karakterističnim učestanostima u frekvencijskom domenu. U duhu generalizacije procesa izdvajanja obeležja na čitavu familiju rotacionih aktuatora daju se sledeće smernice po pitanju izdvajanja karakterističnih parametara: obeležja u vremenskom domenu treba da imaju informacije o relevantnim statističkim parametrima i mogu da budu ista bez obzira na mašinu koja se posmatra, dok obeležja u frekvencijskom domenu moraju biti specifična za problem koji se rešava. Što se frekvencijskog domena tiče, prepostavka je da će na ka-

Tabela 4.1: Izdvojena obeležja signala ventilatorskog mlina u vremenskom i frekvencijskom domenu.

Br.	Opis obeležja	
1	Srednja vrednost	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x(i)$
2	Efektivna vrednost	$x_{rms} = \left(\frac{1}{N} \sum_{i=1}^N x^2(i) \right)^{1/2}$
3	Kvadrat srednje korene vrednosti	$x_r = \left(\frac{1}{N} \sum_{i=1}^N x(i) ^{1/2} \right)^2$
4	Indeks uvrtanja	$x_{ske} = \frac{\sum_{i=1}^N (x(i) - \bar{x})^3}{N x_v^{3/2}}$
5	Kurtosis	$x_{kur} = \frac{\sum_{i=1}^N (x(i) - \bar{x})^4}{N x_v^2}$
6	C faktor	$C = \frac{PP}{x_{rms}}$
7	L faktor	$L = \frac{PP}{x_r}$
8	S faktor	$S = \frac{x_{rms}}{\bar{x}}$
9	Suma amplituda u frekvencijskom domenu na $f_0 \pm 5$ Hz	
10	Suma amplituda u frekvencijskom domenu na $2f_0 \pm 5$ Hz	
11	Suma amplituda u frekvencijskom domenu na $3f_0 \pm 5$ Hz	
12	Suma amplituda u frekvencijskom domenu na $4f_0 \pm 5$ Hz	
13	Suma amplituda u frekvencijskom domenu na $f_p \pm 5$ Hz	
14	Suma amplituda u frekvencijskom domenu na $2f_p \pm 5$ Hz	
15	Suma amplituda u frekvencijskom domenu na $3f_p \pm 5$ Hz	
16	Suma amplituda u frekvencijskom domenu na $4f_p \pm 5$ Hz	

rakterističnim frekvencijama koje oslikavaju kretanje mašine promena signala biti najviše primetna. U slučaju ventilatorskog mlina, kako se udarne ploče troše, performanse su sve lošije i koncentracija uglja u mlinu je sve veća. Samim tim, logično je prepostaviti da će promena biti najvidljivija na osnovnoj frekvenciji rotacije mlina $f_0 = 12.5$ Hz i njenim višim harmonicima. Još jedan efekat koji se očekuje je promena zvučnog potpisa udarne ploče koja prolazi pored mikrofona. Kako ima 10 udarnih ploča unutar mлина, frekvencija prolaska ploče je $f_p = 125$ Hz, tako da se relevantne informacije očekuju na njoj i njenim višim harmonicima. Dakle, finalni skup relevantnih obeležja može da se vidi u tabeli 4.1. Ovde je $x(i)$ i -ti odbirak envelope signala, PP predstavlja razliku između maksimalne i minimalne vrednosti envelope, a x_v predstavlja variansu envelope. Sličnom metodologijom mogu da se izdvoje karakteristične frekvencije za bilo koji drugi rotacioni aktuator, samo treba voditi računa da broj obeležja u vremenskom i frekvencijskom domenu bude približno isti.

4.1.3 Analiza diskriminante

Postoji 16 obeležja izdvojenih iz envelope snimljenog signala, kao što je prikazano u tabeli 4.1, ali nisu sva ona podjednako informativna. S obzirom da će se ova obeležja koristiti za estimaciju istrošenosti radnih kola mлина potrebno je formirati kriterijum tako

da se maksimizira rastojanje između klasa koje opisuju dva ekstremna slučaja: slučaj kada su radna kola zdrava i slučaj kada su potpuno istrošena. Da bi se odredilo koja obeležja su korisna, a koja mogu da se zanemare koristi se analiza diskriminante, tako što se posmatraju matrice unutar-klasnog rasipanja i među-klasnog rastojanja [101].

Klasu koja odgovara zdravim radnim kolima obeležavamo sa ω_1 , dok klasu koja opisuje istrošena radna kola koja treba menjati označavamo sa ω_2 . Uvezši u obzir da je kovarijaciona matrica i -te klase Σ_i , a srednja vrednost M_i , unutar-klasna matrica rasejanja je definisana kao

$$S_W = \sum_{i=1}^L P_i E\{(X - M_i)(X - M_i)^T | \omega_i\} = \sum_{i=1}^L P_i \Sigma_i. \quad (4.1)$$

Ovde je X vektor izdvojenih obeležja, L broj različitih klasa (u trenutnom slučaju važi $L = 2$), a P_i apriorna verovatnoća da će se klasa ω_i pojaviti. Među-klasna matrica rasejanja je

$$S_B = \sum_{i=1}^L P_i (M_i - M_0)(M_i - M_0)^T, \quad (4.2)$$

gde je M_0 kombinovan vektor matematičkog očekivanja za sve klase. Kriterijum separabilnosti klasa je formulisan kao skalarna funkcija J čija vrednost raste kako se međuklasno rastojanje smanjuje, a unutar-klasno rasejanje povećava

$$J = \text{tr}(S_W^{-1} S_B). \quad (4.3)$$

Linearna redukcija dimenzija može da se obavi optimizacijom ovog kriterijuma [101] kao

$$Y_{m \times 1} = A_{n \times m}^T X_{n \times 1}, \quad (4.4)$$

gde je $n = 16$ broj odabralih obeležja, m je broj obeležja posle redukcije dimenzije, a A je transformaciona matrica. Važno je napomenuti da redukovani vektor obeležja, Y , ne mora obavezno da ima neko fizičko značenje. Naime, to je samo linearna kombinacija parametara iz vektora X . Kriterijumska funkcija J se može maksimizovati posmatranjem sopstvenih vrednosti matrice $(S_W^{-1} S_B)_{n \times n}$

$$(S_W^{-1} S_B)_{n \times n} \Psi_i = \lambda_i \Psi_i; i = 1, \dots, n. \quad (4.5)$$

Ovde je Ψ_i sopstveni vektor matrice $(S_W^{-1} S_B)_{n \times n}$ koji ima odgovarajuću sopstvenu vrednost λ_i . Ako se sopstvene vrednosti sortiraju po veličini od najveće ka najmanjoj, $\lambda_1 \geq \lambda_2 \geq$

$\cdots \geq \lambda_n$, onda se matrica A može predstaviti kao

$$A = [\Psi_1 \Psi_2 \cdots \Psi_m]. \quad (4.6)$$

Osim redukcije dimenzija, transformaciona matrica A može da se koristi i za analizu informativnosti specifičnih obeležja prema postavljenom kriterijumu koji je, u ovom slučaju, separabilnost klasa. Ako određeni red matrice A ima značajno manju vrednost od ostalih elemenata matrice, onda obeležje koje odgovara toj vrednosti ne doprinosi mnogo klasifikaciji, pa može da bude zanemareno. Na taj način moguće je smanjiti dimenziju vektora obeležja.

4.2 Binarna procena stanja metodom Bajesovih mreža

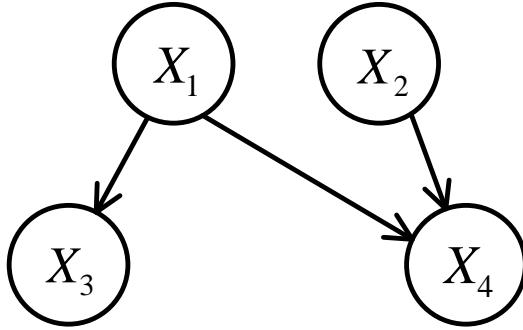
Bajesova mreža je pojam uveden početkom 80ih godina od strane Jude Pearl [113] u pokušaju da kreira matematički alat sposoban da modeluje proces ljudskog razmišljanja. Osnovna ideja je bila da se reprodukuje način na koji ljudi integrišu podatke dobijene iz više izvora i iz njih prave smislene zaključke. Često su podaci koje ljudi koriste prilikom donošenja zaključaka subjektivni, nekompletни, pa čak i nesigurni, te je prirodan početak modelovanja ljudskog rezonovanja njegovo ubacivanje u okvir teorije verovatnoće.

S tim u vidu, korisno je analizirati način na koji ljudi tumače zavisnost između promenljivih. Čak i kada je teško proceniti numeričku vrednost neke uslovne verovatnoće, postojanje ili nepostojanje zavisnosti između dva parametra se lako procenjuje (ako znamo istinu o jednom događaju da li to utiče na naše znanje o nekom drugom događaju?). To nam govori da je shvatanje zavisnosti i uslovnih zavisnosti prirodnije ljudskom razmišljanju od numeričkih vrednosti koje su povezane sa verovatnoćama procena. Ovaj način rezonovanja je suprotan onome što je predstavljeno u većini udžbenika koje se bave verovatnoćom, gde se vrednost uslovne verovatnoće koristi da bi se procenila zavisnost. Priroda zavisnosti između nekih parametara (odnosno tvrdnji) je sličnija povezanosti promenljivih u grafovima (na primer da li promenljiva p direktno utiče na q ili indirektno preko r ?). To sugerije da se ljudski način rezonovanja može prirodnije predstaviti putem grafova i da je razmišljanje duž veza u grafovima zaslužno za zaključivanje i ažuriranje znanja.

Od trenutka kad su nastale, Bajesove mreže su postale izuzetno moćan alat za predstavljanje kompleksnih sistema i korišćene su u mnogim oblastima istraživanja uključujući detekciju i izolaciju otkaza [114, 115]. Jedna velika prednost Bajesovih mreža je u tome što one efektivno predstavljaju kompletan probabilistički model sistema koji je moguće proizvoljno usložnjavati sve dok ne postane u svojoj strukturi adekvatan procesu koji opisuje. Sa druge strane, obučavanje i testiranje ovakvog modela je izuzetno kompjuterski zahtevan problem. Takođe, modularna struktura samih mreža može da predstavlja i veliki nedostatak onda kada se ne poznaje proces dovoljno dobro da bi adekvatna struktura uzročno-posledičnih veza mogla da se napravi.

Bajesove mreže

Bajesova mreža je aciklični usmereni graf koji sadrži skup čvorova i veza između njih i koristi se da predstavi znanje o neizvesnim događajima. U ovoj definiciji graf je usmeren ako su veze između promenljivih u njemu usmerene, a usmereni graf je acikličan



Slika 4.2: Jednostavna Bajesova mreža.

ako ne postoji direktna putanja između čvorova $X_1 \rightarrow X_2 \rightarrow \dots \rightarrow X_n$. tako da je $X_1 = X_n$. Kod Bajesove mreže čvorovi predstavljaju slučajne promenljive koje mogu da budu kontinualne ili diskretne.

Jednostavan tip Bajesove mreže je prikazan na slici 4.2. Ovde veze od čvora X_1 do čvora X_3 i od čvorova X_1 i X_2 do čvora X_4 predstavljaju statističke zavisnosti između odgovarajućih promenljivih. Dakle, vrednost koju uzima promenljiva X_4 zavisi od vrednosti koje imaju promenljive X_1 i X_2 . Čvorovi X_1 i X_2 se zato nazivaju roditeljima promenljive X_4 i, slično, X_4 se naziva detetom promenljivih X_1 i X_2 . U opštem slučaju, za Bajesovu mrežu koja ima n čvorova: X_1, X_2, \dots, X_n , združena verovatnoća se može računati kao:

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | pa(X_i)), \quad (4.7)$$

gde je $pa(X_i)$ skup roditelja čvora X_i .

Postoji mnogo vrsta čvorova koji mogu da se odaberu za neku Bajesovu mrežu, međutim u praksi se uglavnom koriste samo dva tipa: diskretni i kontinualni Gausovski. To je zato što samo za ove dve vrste čvorova može da se izvrši egzaktan račun uslovne verovatnoće [115]. Slično, diskretne promenljive ne mogu da imaju kontinualne roditelje ako se zahtevaju egzaktni proračuni. Dakle, postoje tri različite kombinacije čvorova za odnos roditelj-dete i tri različite metode za računanje uslovnih verovatnoća. Ako diskretne promenljive imaju diskretne roditelje, onda se njihove uslovne verovatnoće predstavljaju preko tabele uslovnih verovatnoća. Drugi slučaj je kada kontinualna promenljiva ima diskretne roditelje i tada ponovo može tabelarno da se pokaže zavisnost uslovnih verovatnoća. U trećem slučaju kontinualne promenljive imaju kontinualne roditelje i tada dolazi do linearne regresije.

Da bi Bajesova mreža bila u potpunosti definisana potrebno je poznavati njenu strukturu (odnosno uzročno-posledične veze između promenljivih) i njene parametre (odnosno kvantitativno opisane uslovne zavisnosti). Postoje dva načina za računanje parametara

Bajesove mreže, kao i njene strukture. Jedan se bazira na ekspertskom poznavanju sistema koji se modeluje, a drugi na mašinskom učenju koristeći eksperimentalne rezultate. Ta dva pristupa mogu da se koriste zasebno ili zajedno.

Pretpostavivši da ekspertsko znanje sistema nije dostupno i da je Bajesovu mrežu potrebno obučiti po strukturi i parametrima, postoji više načina na koje ovo može da se postigne. Korisno je imati u vidu da je učenje strukture mnogo složeniji problem od učenja parametara, tako da je poželjno iskoristiti bilo koje ekspertsko znanje o vezama između promenljivih prilikom inicijalnog modelovanja sistema.

Za sada ćemo prepostaviti da je struktura S Bajesove mreže poznata i da je potrebno naučiti samo parametre p . Ovde struktura S predstavlja sam usmeren aciklični graf koji opisuje mrežu i sastoji se od čvorova i usmerenih veza grafa, a parametri p predstavljaju uslovne verovatnoće koje su dodeljene vezama između promenljivih.

U slučaju kada su čvorovi Bajesove mreže opservabilni, najčešći algoritam za mašinsko učenje je estimator maksimalne verodostojnosti [116]. Tu je cilj da Bajesova mreža usvoji uslovne gustine verovatnoće koje opisuju veze između promenljivih tako da se maksimiziraju verovatnoće obučavajućeg skupa. Odnosno, ako postoji Bajesova mreža $B = (S, p)$ sa definisanom strukturom S i parametrima p , i ako je D skup obučavajućih podataka sa vrednostima svih parametara p mreže B , tada je cilj da se maksimizira verovatnoća podataka $d \in D$, pod uslovom da je poznata Bajesova mreža B :

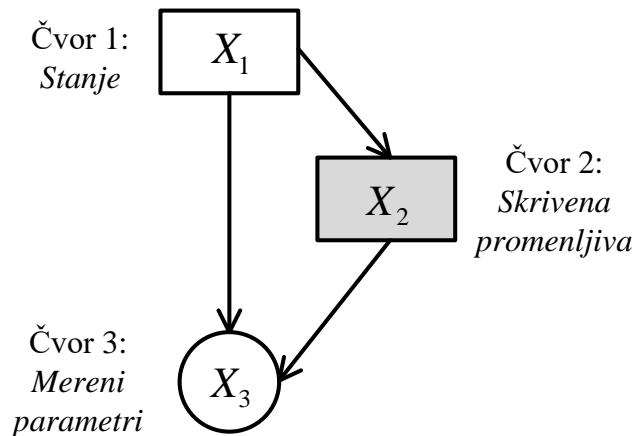
$$L(B|D) = \prod_{d \in D} P(d|B). \quad (4.8)$$

Često se ovaj problem maksimizacije predstavlja u logaritamskoj formi radi jednostavnijeg računa:

$$LL(B|D) = \sum_{d \in D} \log_2 P(d|B). \quad (4.9)$$

Ako postoji izbor između više struktura Bajesovih mreža, dobro je usvojiti model koji daje maksimalnu verovatnoću uvezši u obzir dobijene podatke.

Često je slučaj, međutim, da se ne mogu svi parametri direktno meriti i da se veza između čvorova mora modelovati neopservabilnim, skrivenim promenljivima. To su promenljive čije vrednosti ne znamo i koje se pojavljuju u modelu da bi predstavile neki šum ili grešku modelovanja. U tim slučajevima se metoda logaritamske verovatnoće predstavljena ovde ne može koristiti i mora da se primeni aproksimativna estimacija parametara. Najčešće korišćen aproksimativni algoritam za obučavanje Bajesove mreže sa skrivenim čvorovima je maksimizacija očekivanja (engl. *expectation maximization*, EM). Ovaj algoritam se sastoji iz dva koraka. U prvom koraku, koji se zove korak očekivanja, koristi



Slika 4.3: Bejsova mreža za binarnu klasifikaciju.

se trenutna estimacija parametara p da bi se izračunalo očekivanje nedostajuće vrednosti skrivene promenljive. Onda se u drugom koraku, koji se zove korak maksimizacije, pravi nova estimacija maksimalne verodostojnosti parametara. Posle ovoga se algoritam vraća na prethodni korak i postupak se nastavlja duž celog obučavajućeg skupa.

Model za detekciju stanja

Tokom poslednjih nekoliko decenija Bajesove mreže su postale moćno sredstvo za predstavljanje kompleksnih sistema u kojima postoji velika količina nesigurnosti i počele su da se koriste u mnogim oblastima istraživanja, uključujući i detekciju i izolaciju otkaza [117]. Najveći problem kod Bajesovih mreža predstavlja samo određivanje modela koji adekvatno predstavlja sistem koji se posmatra. Prvi korak u modeliranju je odabir relevantnih promenljivih sistema. One mogu da predstavljaju fizičke, merljive osobine sistema ili neku nepoznatu smetnju koja ne može da se izmeri. Zatim treba napraviti odluku o vrsti odabranih promenljivih. One mogu da budu diskretne ili kontinualne, vidljive ili skrivene. Sledeći korak je odluka o strukturi Bajesove mreže. Ovo je najznačajnije i najkompleksnije pitanje. Postoji mnogo različitih vrsta struktura, a glavne smernice leže u poznavanju kauzalnih veza unutar samog sistema i u ograničenju kompleksnosti sistema.

U ovoj disertaciji, za potrebe detekcije stanja, predložena je jednostavna struktura Bajesove mreže koja je prikazana na slici 4.3. Ovde krugovi predstavljaju kontinualnu slučajnu promenljivu, kvadrati diskretnu, bela polja predstavljaju vidljive čvorove, a siva polja skrivene promenljive (promenljive čije vrednosti ne znamo i ne možemo da izmerimo). Ova mreža sadrži samo tri slučajne promenljive od kojih su dve diskretne i jedna kontinualna.

Osnovna ideja kojom se rukovodimo u ovoj Bajesovoj mreži je da stanje mašine koje

treba proceniti direktno utiče na dobijena merenja, ali da postoji i indirektan uticaj preko skrivene promenljive. Ova skrivena promenljiva može da predstavlja neki šum, nepoznatu komponentu sistema koji se modeluje ili neku drugu osobinu koja ne mora da ima fizičko značenje. U modelu Bajesove mreže prikazanom na slici 4.3 nije uzeta u obzir verovatnoća prelaska jednog stanja u drugo, pa je time dobijena ušteda na kompleksnosti modela. Diskretan čvor X_1 može da ima onoliko dimenzija koliko ima stanja. Kažemo da je u pitanju binarna klasifikacija zato što smo usvojili dva moguća stanja koja X_1 može da ima: stanje zdravih i stanje istrošenih udarnih ploča. Promenljiva X_3 ima onoliko dimenzija koliko ima merenih podataka, ili relevantnih elemenata merenih podataka (odnosno obeležja).

Rezultati

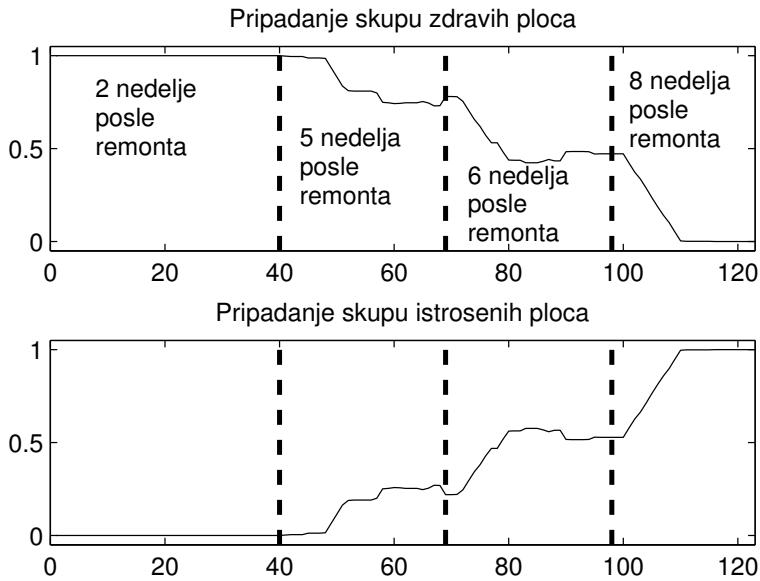
Za testiranje algoritma koristi se jednostavna Bajesova mreža sa slike 4.3. Prva promenljiva X_1 predstavlja realno stanje sistema i biramo da bude diskretna promenljiva sa dva moguća stanja – stanje zdravih i stanje istrošenih ploča. Druga promenljiva X_2 je skrivena i ne mora da ima određeno fizičko značenje. Ona predstavlja šum u okruženju koji može da utiče na merenja, kao i nepoznate parametre sistema koji nisu na drugi način uključeni u model. Nju smo takođe odabrali kao diskretnu promenljivu sa dva moguća stanja. Konačno, treća promenljiva X_3 predstavlja merene izlaze iz sistema. U ovom slučaju to je parametar Y dođen primenom tehnika za pretprocesiranje signala iz jednačine 4.4. Ova promenljiva je izabrana da bude kontinualna i Gausovska. S tim u vidu, združena verovatnoća ove Bajesove mreže je

$$P(X_1, X_2, X_3) = P(X_3|X_1, X_2) P(X_2|X_1) P(X_1). \quad (4.10)$$

Da bismo odredili stanje udarnih ploča potrebno je izračunati verovatnoću svakog od stanja iz X_1 ako nam je poznato merenje X_3 .

Obučavanje i testiranje ove Bajesove mreže vrši se koristeći signale snimljene u okolini ventilatorskog mlina, u periodima prikazanim na slici 4.1. Za obučavanje skup uzeti su snimci načinjeni neposredno pre i posle remonta, time predstavljajući dva ekstremna skupa stanja udarnih ploča. Pošto u sistemu postoji skrivena promenljiva, X_2 , za obučavanje je korišćen algoritam baziran na maksimizaciji očekivanja (EM algoritam) opisan u prethodnom segmentu. Rezultati testiranja za 122 snimka u različitim stadijumima istrošenosti mlina prikazani su na slici 4.4.

Jasno je da je Bajesova mreža uspešno detektovala stanje udarnih ploča. Iako je suštinski u pitanju problem binarne klasifikacije (čvor X_1 proverava da li je mlin zdrav ili



Slika 4.4: Rezultati testiranja na 122 snimka u različitim stadijumima istrošenosti ploča.

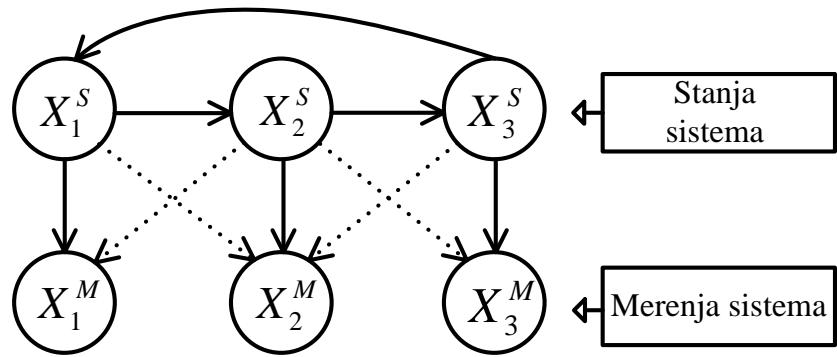
istrošen), rezultujuća metrika u vidu verovatnoće pripadanja skupu zdravih ili skupu istrošenih ploča je kontinualna. Da bi se spričile nagle promene u proceni stanja koju daje Bajesova mreža njen izlaz se usrednjavao na svakih 10 vremenskih trenutaka.

Predlog složenih struktura Bajesovih mreža

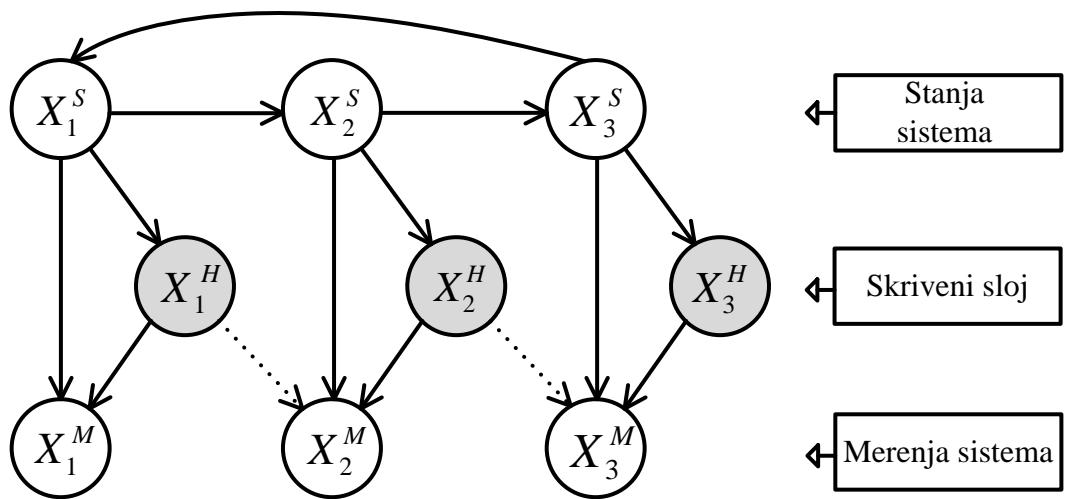
Jednostavna struktura topologije Bajesove mreže sa slike 4.2 se pokazala kao dovoljno dobra za primer estimacije stanja mlinova. Međutim, s obzirom da loša procena strukture može da napravi jako veliki problem prilikom klasifikacije, u okviru ovog poglavlja biće predložene još dve strukture koje mogu da se koriste u ove svrhe ali uzimaju u obzir složeniju dinamiku samog sistema.

Prva struktura se odnosi na skrivene Markovljeve modele. Oni su podvrsta Bajesovih mreža u kojima naredno stanje sistema zavisi od prethodnog stanja i verovatnoće prelaska iz prethodnog u naredno stanje. Zove se skriveni zato što stanja modela nisu direktno merena, već utiču na merene veličine iz kojih se posle zaključuje o stanju sistema. Skriveni Markovljevi modeli se koriste za veoma širok dijapazon problema, a jedan takav model (slika 4.5) se može koristiti za detekciju otkaza.

Na slici 4.5 čvor X_i^S predstavlja stanje sistema, a X_i^M merenje vršeno na sistemu. U ovom primeru su sve promenljive odabrane tako da budu kontinualne i vidljive, ali to generalno ne mora da bude slučaj. Na slici je odabранo da postoji 3 stanja. Ako bismo, na primer, posmatrali istrošenost nekog elementa mašine, ta stanja bi predstavljala stanje zdrave mašine (X_1^S), stanje u kome se element koristi neko vreme ali i dalje nije izraženo



Slika 4.5: Skriven Markovljev model.



Slika 4.6: Složen dinamički model.

mehaničko trošenje (X_2^S) i stanje u kome je trošenje izraženo (X_3^S) i koje nam govori da treba da se vrši remont. U ovom konkretnom modelu prelazak iz jednog u drugo stanje je izvršen tako da se stanje maštine pogoršava sve do trenutka kada je remont neophodan, i tek tada stanje maštine može da se vratи u početnu tačku zdravih elemenata. Takođe, svako stanje daje odgovarajuća merenja, međutim prisustvo šuma ili poremećaja može da utiče na to da merenje u datom trenutku više odgovara nekom od susednih stanja. Ova zavisnost predstavljena je istačkanim linijama na slici 4.5.

Markovljevi modeli spadaju u jednostavnije strukture Bajesovih mreža, ali ona lako može da se modifikuje da uključi kompleksnije zahteve sistema. Jedna takva modifikacija je predložena na slici 4.6 gde je inkorporirana mešavina prethodna dva primera Bajesovih mreža. Ovde je uključen dinamični prelazak stanja iz jednog u drugo, kao i postojanje skrivene promenljive koja utiče na dobijena merenja.

4.3 Kontinualna estimacija stanja

Jedini način da se zaista detektuje količina istrošenosti elemenata neke mašine je da se kontinualno prati njena promena stanja. Ovo je teško izvodljivo korišćenjem tradicionalnih metoda iz prostog razloga što između dva ekstremna stanja - stanje zdravih i stanje potpuno istrošenih elemenata - postoji beskonačno mnogo među-koraka kroz koje sistem prolazi. Običiti algoritme za svaku od ovih promena ponaosob nije realno ostvarivo. Zato je potrebno napraviti metriku koja predstavlja meru istrošenosti elemenata i koja se kontinuirano menja sa promenom stanja mašine.

Dve metode sa ovim osobinama su razvijene u okviru disertacije i biće opisane u ovom segmentu rada: metoda procene statističke distance i metoda suptraktivne klasterizacije. Obe metode imaju dva režima rada: režim obučavanja u okviru kojeg se prikupljaju informacije o dva ekstremna stanja mašine (pre i posle remonta) i režim monitoringa kada se procenjuje količina istrošenosti elemenata. Obe metode mogu da se primenjuju u realnom vremenu ili u *offline* analizi.

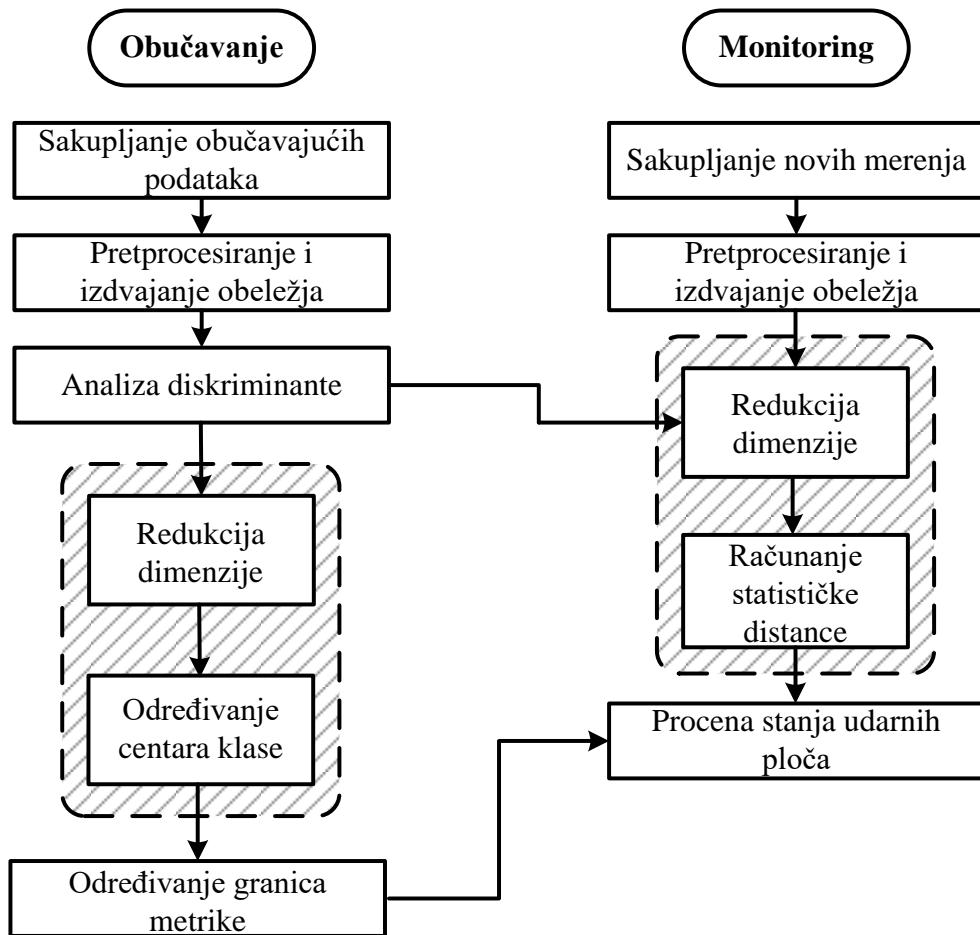
Efikasnost razvijenih algoritama se testira u dva koraka. Prvo se verifikuje da li klase zdravih i istrošenih udarnih ploča mogu jasno da se razlikuju (odnosno da li obučavanje algoritma zaista proizvodi dve separabilne klase). Drugi korak je verifikacija da testirajući snimci iz stadijuma monitoringa zaista postepeno prelaze od klase zdravih ka klasi istrošenih udarnih ploča kako se broj radnih sati povećava.

4.3.1 Metoda procene statističke distance

Metoda procene statističke distance se bazira na linearnoj redukciji dimenzija optimizacijom kriterijuma baziranom na matrici rasejanja i njen tok izvršavanja se može videti na slici 4.7. Ona se u osnovi oslanja na algoritam za redukciju dimenzija, tako da je osigurana od predimenzionisanja vektora obeležja.

Izvršavanje algoritma

Redukcija dimenzija se vrši na osnovu jednačine 4.4, gde se $n = 16$ obeležja redukuje na dvodimenzionalni prostor, dakle $m = 2$. Prvo se obučavajući podaci prikupe iz dve ekstremne klase: klasu zdravih udarnih ploča (snimci načinjeni neposredno posle remonta) i klasu istrošenih ploča (snimci neposredno pre remonta). Statistički parametri obeležja dobijenih iz ove dve klase su korišćeni za računanje matrice A kao u jednačini 4.6. Posle toga nastupa stadijum monitoringa.

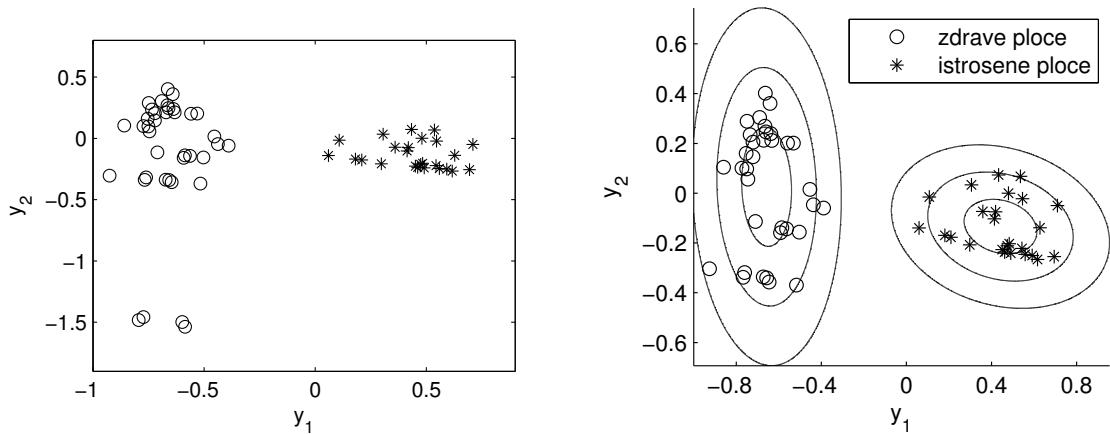


Slika 4.7: Tok izvršavanja metode bazirane na proceni statističke distance.

Tokom monitoringa snimci se uzimaju na svakih nedelju-dve dana i obeležja se izdvajaju iz preprocesiranih signala. Posle toga se vrši redukcija dimenzija u dvodimenzionalni prostor. Da bi se numerički predstavio nivo istrošenosti udarnih ploča pomoću ovih dvodimenzionalnih vektora koristi se statistička distanca testirajućeg vektora X od obučavajućeg skupa zdravih ploča. Ako su srednja vrednost i kovarijansa obučavajućeg skupa M i Σ respektivno, onda se statistička distanca dobija kao

$$d_{M1}^2 = (X - M)^T \Sigma^{-1} (X - M). \quad (4.11)$$

Dakle, što je veća statistička distanca d_{M1}^2 , veća je i istrošenost ploča, tako da rezultat iz 4.11 može da se koristi kao mera istrošenosti mehaničkih elemenata. Kada ta vrednost pređe određenu granicu, to znači da su ploče istrošene i da ih je potrebno zameniti. Sama granica se formira u toku obučavanja algoritma.



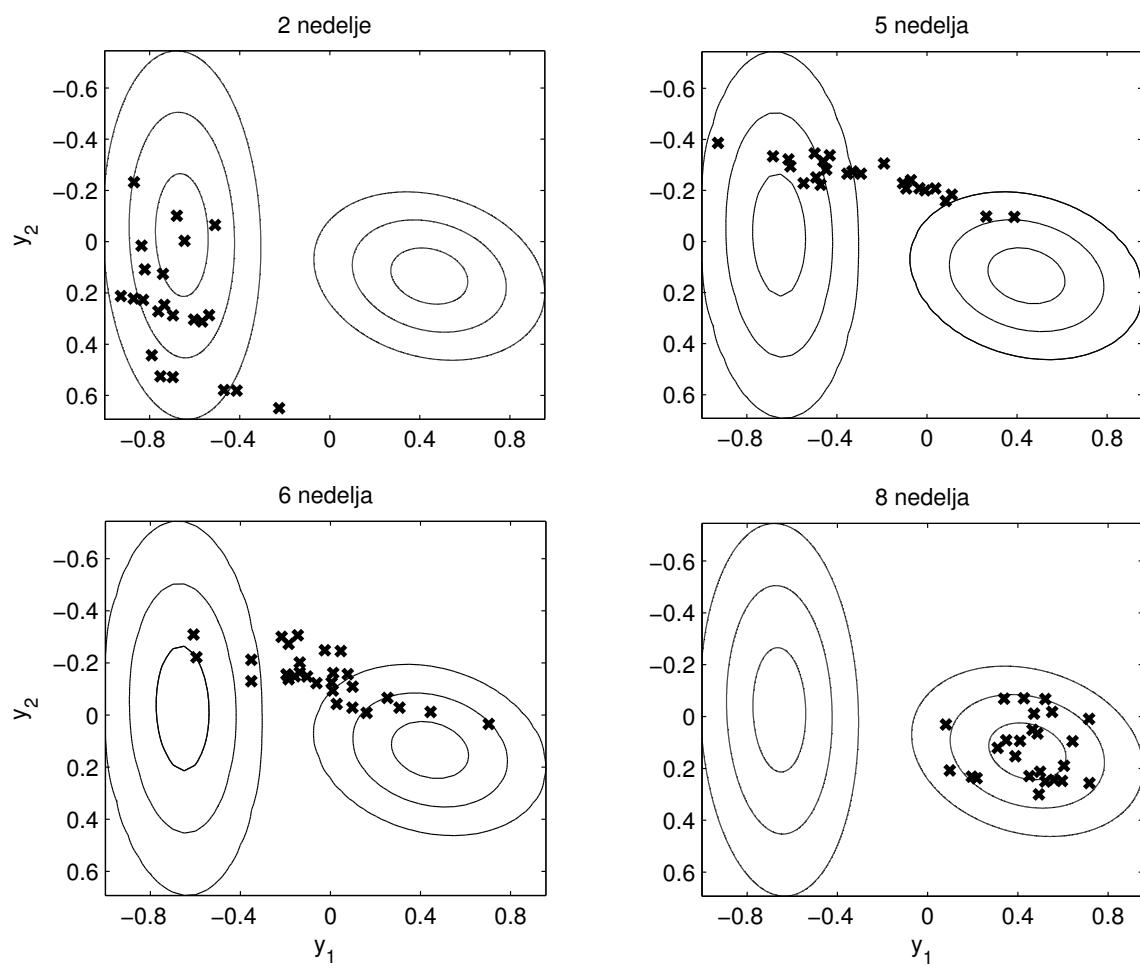
Slika 4.8: *Obučavanje metode bazirane na proceni statističke distance.*

Rezultati

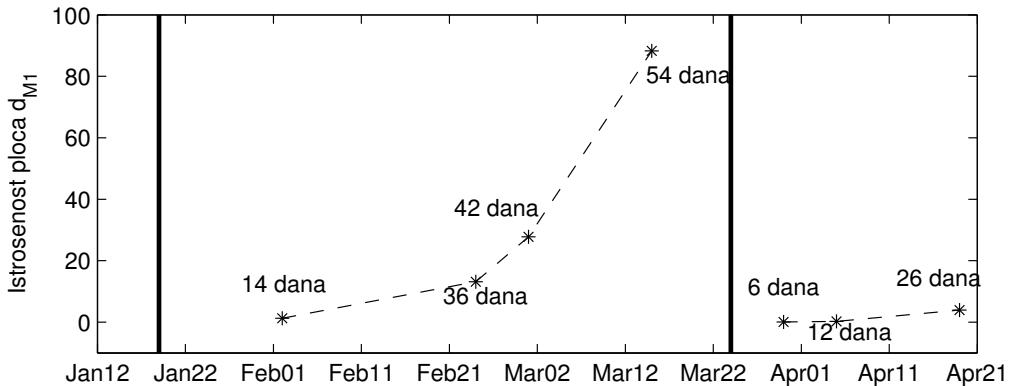
Po izdvajaju obeležja iz obučavajućih snimaka, kriterijumska funkcija se optimizuje i dobija se matrica A za redukciju dimenzija. Rezultat obučavanja algoritma može se videti na slici 4.8 (levo). Jasno se vidi da zaista postoje dve separabilne klase koje predstavljaju stanje zdravih i istrošenih udarnih ploča. Zanimljivo je primetiti da postoje 4 odbirka u klasi zdravih ploča koja su donekle pomerena u odnosu na glavni deo skupa. Ovo je izazvano impulsnim šumom koji prethodno nije uklonjen, a zbog načina predobrade signala, taj šum je vidljiv u 4 različita segmenta. Ovaj fenomen potvrđuje tvrdnju koju smo izneli ranije, a to je da estimatori stanja bazirani na korišćenju akustičkih signala imaju jako veliku osetljivost na zašumljena merenja. Obučavajući skup bez zašumljenih merenja i sa naznačenim statističkim distancama $d^2 \in \{1, 4, 9\}$ može se videti na slici 4.8 (desno).

Sledeći korak u proveri algoritma je verifikacija rezultata testiranja za ostale skupove snimljenih signala i provera da li se algoritam za redukciju dimenzija ponaša konzistentno (odnosno, da li se skup izdvojenih obeležja pomera od skupa zdravih ka skupu istrošenih ploča kako se povećava broj radnih sati). Rezultati za jedan životni ciklus radnih kola mogu se videti na slici 4.9 gde su prikazani testirajući skupovi u odnosu na statističke distanse obučavajućih skupova zdravih i istrošenih radnih kola. Prikazano je ponašanje u četiri vremenska trenutka: dve nedelje posle remonta (gore levo), pet nedelja posle remonta (gore desno), šest nedelja posle remonta (dole levo) i osam nedelja posle remonta (dole desno). Vizuelnom inspekcijom se dolazi do jasnog zaključka da se testirajući snimci pomeraju od skupa zdravih ka skupu istrošenih ploča kako se povećava broj radnih sati.

Na kraju je izračunata statistička distanca testirajućih odbiraka radi merenja stanja



Slika 4.9: *Testiranje metode bazirane na proceni statističke distance sa naznačenim periodom proteklom od poslednjeg remonta.*



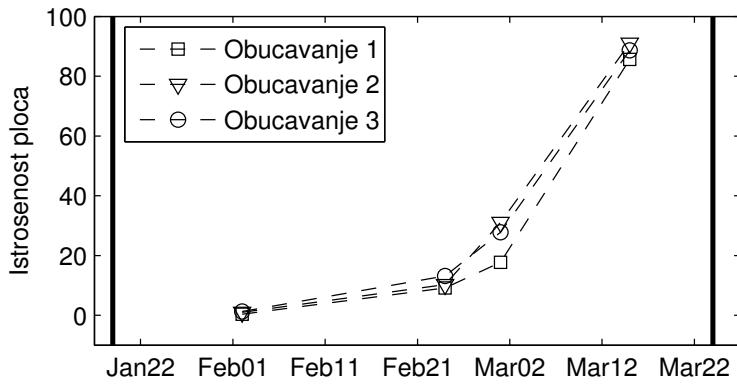
Slika 4.10: *Mera istrošenosti udarnih ploča izračunata metodom baziranom na proceni statističke distance.*

udarnih ploča. Rezultat je prikazan na slici 4.10. Jasno se vidi postepena degradacija kvaliteta ploča u toku njihovog životnog ciklusa. Svaki snimak je označen na grafiku, a vertikalne linije ukazuju na periode kada je vršen remont. Takođe, pored svake sesije snimanja jasno je naznačen broj radnih dana od poslednjeg remonta. Sa slike se vidi da se udarne ploče postepeno troše u prvoj polovini njihovog životnog ciklusa, a ta degradacija je značajno brža kako se približavaju kraju životnog veka. Kada statistička distanca pređe vrednost $d_{M1}^2 = 80$ potrebno je da se obavi remont.

Napomena

Jedan od velikih nedostataka statističkih metoda klasifikacije koje se baziraju na višedimenzionom vektorskom prostoru je potencijalna nemogućnost algoritma da generalizuje rezultate. Kako se broj obeležja povećava, mnogi statistički algoritmi zahtevaju eksponencijalno povećanje merenja da bi zadržali statističku relevantnost. U suprotnom algoritam se ne može adekvatno obučiti i dolazi do preobučavanja. Ako je algoritam sklon preobučavanju njegovo ponašanje će značajno da varira u zavisnosti od obučavajućeg skupa koji se koristi i neće imati dobre performanse kada dobije testirajuće podatke.

Ovaj algoritam jeste sposoban da pravilno interpretira nove testirajuće podatke, kao što se to vidi sa slike 4.10. Međutim, da bi se dalje osigurala sposobnost generalizacije algoritma iskorišćena je poznata tehnika kros-validacije koja se zove *leave-many-out* metoda. To znači da je obučavajući skup podeljen na obučavajući podskup (80% odbiraka) i podskup za validaciju (20% odbiraka) koji je pridružen ostalim testirajućim skupovima. Ovo je ponovljeno tri puta i svaki put su različiti odbirci isključeni iz procesa obučavanja. Rezultati se mogu videti na slici 4.11 i ukazuju na to da se algoritam ponaša na sličan



Slika 4.11: Ilustrativna validacija predložene metode bazirane na proceni statističke distancije.

način prilikom svakog obučavanja, i da je svaki put sposoban da detektuje stanje maštine. Samim tim, može se zaključiti da nije došlo do preobučavanja.

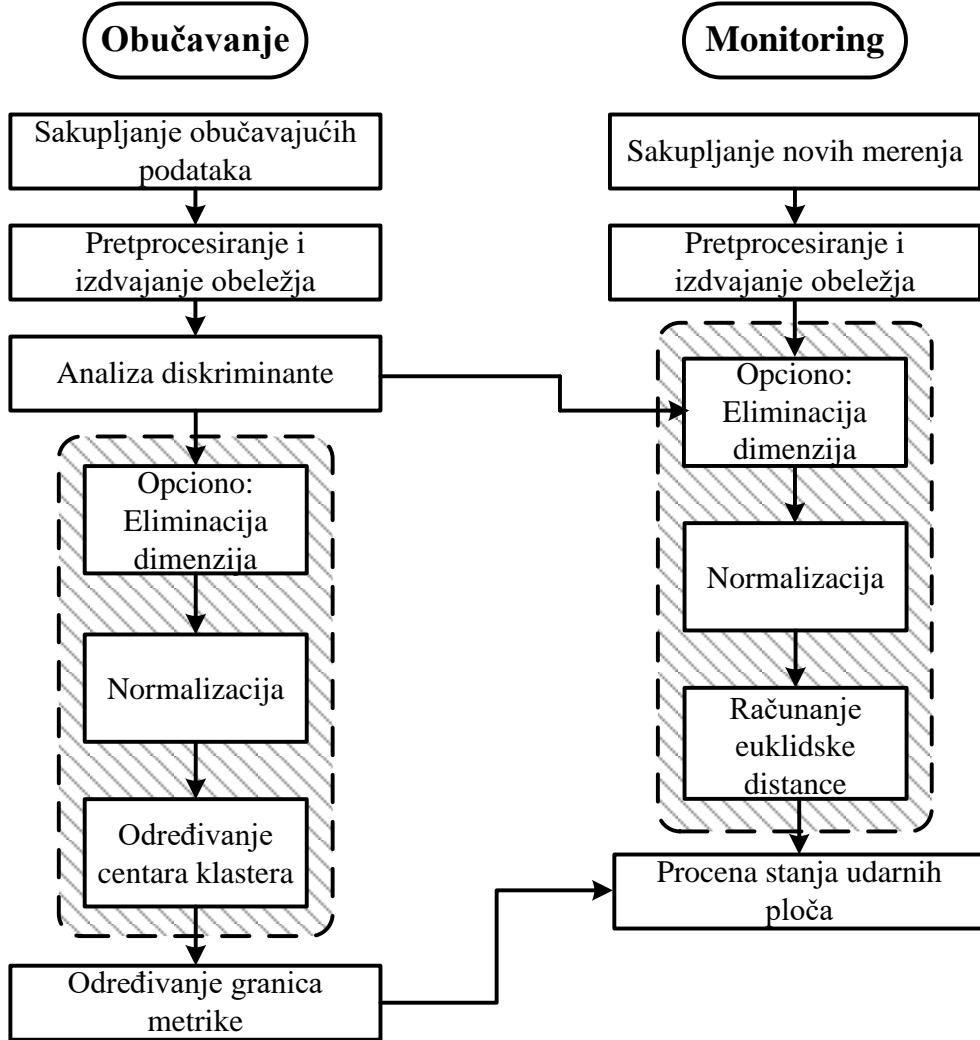
4.3.2 Metoda suptraktivne klasterizacije

Metoda suptraktivne klasterizacije (engl. *subtractive clustering*) se koristi za procenu stanja udarnih ploča bez prethodne redukcije dimenzija i njen tok izvršavanja se može videti na slici 4.12. Umesto redukcije dimenzija ova metoda izvlači informacije o nivou istrošenosti udarnih ploča iz višedimenzionog prostora obeležja. Poznato je [101] da statistička distanca nije mnogo informativna kada se dimenzionalnost prostora povećava, tako da je neophodna alternativna metrika za slučajeve kada je broj dimenzija veći od 2.

Izvršavanje algoritma

Tehnika koja je iskorišćena za prevazilaženje ovog problema je procedura klasterizacije koja se zove suptraktivna klasterizacija i koja je prvi put predložena od strane Chiua [118] za identifikaciju fazi modela. Iako su metode klasterizacije najčešće primenjivane onda kada je neophodno obučavanje bez supervizije, u ovoj metodi se koristi kao efikasan i računski jednostavan način da se odrede centri klastera u skupu višedimenzionih podataka [119], kako bi se na osnovu njih odredila količina istrošenosti mlina.

Ova metoda je osetljiva na velike promene u rasponima obeležja, tako da je svako obeležje normalizovano na interval $[0, 1]$. Tokom faze obučavanja matrica A može da se koristi za analiziranje obeležja uz moguću eliminaciju nekih od njih iz skupa podataka. Ovo nije obavezan korak, ali može da se primeni ako se zaključi da je originalni broj obeležja preveliki. Centar prvog klastera je odabran računanjem mere gustine svake tačke



Slika 4.12: *Tok izvršavanja metode bazirane na suptraktivnoj klasterizaciji.*

obučavajućeg skupa

$$D_i = \sum_{j=1}^N \exp\left(-\frac{\|X_i - X_j\|^2}{(r_a/2)^2}\right). \quad (4.12)$$

Tačka X_{c_1} koja ima najveću meru gustine D_{c_1} je odabrana kao centar prvog klastera. Posle toga mera gustine je ažurirana kao

$$D_i^{new} = D_i - D_{c_1} \exp\left(-\frac{\|X_i - X_{c_1}\|^2}{(r_b/2)^2}\right). \quad (4.13)$$

Slično, centar drugog klastera je odabran kao tačka u skupu obeležja sa najvećom ažuriranim merom gustine. U jednačinama 4.12 i 4.13, N predstavlja broj odbiraka obučavajućeg skupa, a $r_a = 1$ i $r_b = 1.5$ su pozitivne konstante koje predstavljaju prečnik oblasti u okviru koje tačke utiču na funkciju gustine.

Načelno, suptraktivna klasterizacija ne podrazumeva da je unapred poznat broj klastera. Kada jeste poznat [119] procedura je prilično pojednostavljena u smislu da je neophodno izračunati samo unapred definisanu količinu centara klastera. Sa druge strane, kada broj klasa nije poznat koristi se jednačina 4.13 za računanje centara različitih klastera dok mera gustine ne zadovolji uslov predložen u [118]. S obzirom da u problemu estimacije stanja inicijalno želimo da analiziramo ponašanje u odnosu na dve klase, procedura obučavanja se završava onda kada su oba centra klastera izračunata.

Posle faze obučavanja dolazi faza monitoringa, a kao mera istrošenosti usvaja se prosečni odnos euklidskog rastojanja testirajućeg vektora od dva ekstremna skupa, na sledeći način:

$$d_{M2} = \frac{1}{N} \sum_{i=1}^N \frac{\|X_i - X_{c_H}\|}{\|X_i - X_{c_W}\|}. \quad (4.14)$$

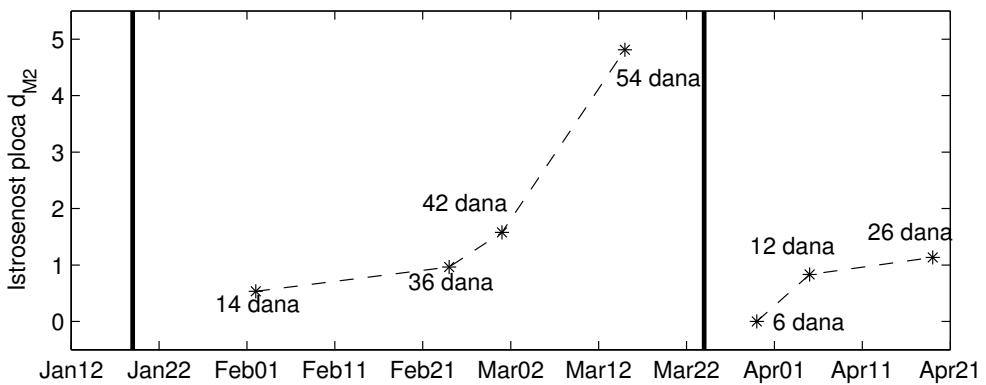
Ovde se X_{c_H} odnosi na centar klastera koji odgovara skupu zdravih ploča, a X_{c_W} označava centar klastera koji odgovara skupu istrošenih ploča. Što je bliže testirajući skup skupu istrošenih ploča, veća je mera istrošenosti, sve dok se ne pređe prag koji ukazuje na to da je neophodno izvršiti remont.

Rezultati

Za ovu metodu računanje transformacione matrice A je opcionalo i može da se koristi za analizu informativnosti svakog od obeležja za potrebe separabilnosti klasa. Centri klastera se računaju u 16-dimenzionom prostoru obeležja koristeći jednačine 4.12 i 4.13. Naknadna verifikacija ovog obučavanja bez supervizije je pokazala da centar prvog klastera odgovara klasi zdravih udarnih ploča, dok centar drugog klastera odgovara skupu istrošenih udarnih ploča. Zbog visoke dimenzionalnosti problema rezultati obučavanja se ne mogu adekvatno grafički prikazati.

Proces monitoringa može da počne čim su dobijene informacije o poziciji centra klastera, a mera predložena u jednačini 4.14 može da se odredi za odbirke svake snimane sesije. Rezultati su prikazani na slici 4.13. Slično kao kod prethodne metode, jasno se vidi postepena degradacija udarnih ploča kako se broj radnih sati povećava. Remont je neophodan onda kada prosečni odnos euklidskih distanci pređe vrednost $d_{M2} = 4$.

Vrednosti koje se vide na slici 4.13 donekle mogu da variraju u zavisnosti od količine obeležja koji je usvojen, od originalnih 16. Ako se usvoji bilo koji broj relevantnih obeležja koji je veći od 12 grafik će imati sličan oblik kao onaj koji je prikazan, a nastavkom smanjivanja broja obeležja tačna estimacija postaje nemoguća. S tim u vidu sugerise se korišćenje opcije eliminacije dimenzija samo onda kada se sa sigurnošću zna da su



Slika 4.13: Mera istrošenosti udarnih ploča izračunata metodom suptraktivne klasterizacije.

obeležja koja se eliminišu nedvosmisleno neinformativna.

4.4 Kratak rezime

U okviru ovog poglavlja predstavljena su rešenja problema detekcije estimacije rotacionih aktuatora korišćenjem akustičkih signala. Predstavljena je metoda izdvajanja obeležja iz zvučnog signala koja se može primeniti na široku familiju rotacionih aktuatora. Takođe, predstavljena su tri rešenja problema detekcije stanja koristeći izdvojena obeležja: rešenje bazirano na Bajesovim mrežama, na redukciji dimenzija i na suptraktivnoj klasterizaciji. Sve metode su testirane na realnim signalima ventilatorskog mlina u termoelektrani u cilju detekcije istrošenosti udarnih ploča.

Izdvajanje obeležja je bazirano na pretpostavci koja je dobro utemeljena u literaturi, a to je pretpostavka o ciklostacionarnosti zvučnih signala rotacionih aktuatora. Sa tim u vidu, predlaže se izdvajanje obeležja u vremenskom i frekvencijskom domenu i to: standardne statističke karakteristike signala u vremenskom domenu i amplitude na karakterističnim frekvencijama u frekvencijskom domenu.

Predložena je i testirana jednostavna struktura Bajesove mreže koja opisuje dinamiku i uzročno-posledične veze istrošenosti udarnih ploča na karakteristike zvučnog signala. Binarna estimacija stanja je uspela da detektuje nivo istrošenosti i predložene su još neke kompleksnije strukture za potrebe detekcije stanja u složenijim sistemima. Ovo je računski najzahtevnija od svih predloženih metoda za estimaciju stanja, tako da je preporučljivo implementirati je na nekom sistemu kod koga benefiti te kompleksnosti mogu da dođu do izražaja, na primer na složenom sistemu sa izuzetno spregnutim uzročno-posledičnim vezama između parametara.

Poslednje dve metode za detekciju stanja se baziraju na standardnim algoritmima za prepoznavanje oblika (redukcija dimenzija sa metrikom u vidu statističke distance i suptraktivna klasterizacija sa metrikom u vidu odnosa euklidskih distanci). Oba algoritma uspevaju da detektuju količinu istrošenosti sa vrlo sličnim performansama. Dok je prva metoda pogodna za grafički prikaz zato što koristi redukovane vektore obeležja u dvodimenzionalnom prostoru, druga metoda je računski jednostavnija s obzirom da u originalnom prostoru obeležja samo računa distance od centara klastera.

Glava 5

Zaključak

Prediktivno održavanje postrojenja, a posebno problem detekcije stanja mašina, od izuzetno je velike važnosti u modernoj industriji. Posedovanje tačnih informacija o efikasnosti i načinu funkcionisanja uređaja je višestruko korisno: sa finansijskog aspekta donosi mnoge uštede jer omogućava optimizaciju organizacije popravki i remonta, a sa druge strane, unapređuje bezbednost samog postrojenja tako što značajno smanjuje verovatnoću da dođe do naglih otkaza i havarijskih situacija. Procena stanja rotacionih aktuatora, kao jednih od najzastupljenijih vrsta aktuatora u industriji, je posebno značajna za ove svrhe. Zbog cikličnog rotacionog kretanja koje je karakteristično za ovu vrstu mašina, vibracioni potpis koji oni proizvode ima vrlo specifičan oblik i nosi pregršt informacija o njihovom funkcionisanju. Postoje dva načina da se ovaj vibracioni potpis izmeri. Direktan način koristi senzore vibracije koji moraju da se postavljaju na samu mašinu, pa samim tim zahtevaju veliku stručnost radnika koji ih postavlja, često moraju da budu termoizolovani i invazivnog su karaktera, tako da u nekim slučajevima mogu da ometaju rad mašine. S obzirom da vibracija mehaničkih struktura utiče na prostiranje zvuka, indirektni način merenja promena u vibracionom potpisu je korišćenje akustičkih senzora kao što su mikrofoni. U ovom slučaju senzori se postavljaju u okolini mašine, neinvazivnog su karaktera i praktičniji su za primenu zato što se mogu koristiti za više uređaja.

Trenutno se problem prediktivnog održavanja rotacionih aktuatora u realnim industrijskim postrojenjima najčešće rešava uz pomoć signala vibracije, iako je informativnost zvučnih signala u te svrhe dokazana u laboratorijskim uslovima još pre dve decenije. Razlog za slabo korišćenje zvučnih merenja u industriji je čisto praktičnog karaktera i odnosi se na njihovu veliku osetljivost na okolni šum koji u realnim uslovima ne može da se izbegne. Takođe, algoritmi za detekciju stanja mašina koji se pojavljuju u literaturi su

uglavnom realizovani i testirani samo za specifičan uređaj i teško mogu da se generalizuju na širu familiju uređaja. Cilj ove disertacije jeste razvijanje nove metodologije za detekciju stanja koja koristi signale zvuka snimljene u realnom industrijskom okruženju i koja se lako može generalizovati na čitavu familiju rotacionih aktuatora. Da bi se ovo uspešno realizovalo potrebno je obezbediti robusnost algoritma za estimaciju stanja na šum i predložiti metodu za izdvajanje obeležja iz signala zvuka koja se lako može prilagoditi bilo kakvom tipu rotacionog aktuatora. Ove funkcionalnosti su obezbeđene tako što je prvo razvijen algoritam za pretprocesiranje koji ima za cilj da detektuje kontaminaciju zvučnog signala i na taj način spreči kontaminirane segmente da dođu do algoritma za estimaciju stanja. Posle toga je predložena metoda za izdvajanje obeležja koja je primenjiva na sve rotacione aktuatore i na kraju je razvijen algoritam za estimaciju stanja koji, koristeći nekontaminirane odbirke koji su prošli kroz predobradu, može da detektuje stanje machine. Svi algoritmi razvijeni u okviru ove disertacije su testirani na realnim akustičkim signalima snimljenim u okolini ventilatorskog mlina u termoelektrani Kostolac A1.

Predložena su tri algoritma za detekciju kontaminacije zvučnog signala. Jedan je baziran na analizi statističkih parametara signala korišćenjem QQ krive i ima za cilj da eliminiše segmente u kojima prepozna kontaminaciju, a nekontaminirane delove propusti dalje do algoritma za estimaciju stanja. Na taj način omogućena je robustifikacija već postojećih algoritama za prediktivno održavanje, a otvoren je i prostor razvijanju novih koji ne moraju da vode računa o mogućoj zašumljenosti. Detekcija kontaminacije se obavlja poređenjem statističkih parametara snimljenog signala i parametara izmerenog segmenta, pa se u odnosu na količinu i način odstupanja donosi procena o tome da li je do kontaminacije došlo ili ne. Velika prednost ovog algoritma je u tome što je adaptivan na promene u nominalnom režimu rada aktuatora, tako da nije neophodno menjati ga i korigovati svaki put kada dođe do neke izmene u okruženju u kome se primenjuje. Algoritam je testiran na zvuku snimljenom u okolini mlina na kome je izraženo pojavljivanje dve vrste realnih kontaminacija: zagađenost govorom i impulsni šum. U okviru snimljenog segmenta je obuhvaćen i deo u kome se mikrofon pomera u odnosu na svoj originalni položaj i na taj način je simulirana promena u nominalnim parametrima akustičkog okruženja. Zaključeno je da algoritam jako dobro detektuje pojavu impulsnog šuma i promenu nominalnog režima (odnosno pomeranje mikrofona), ali procenat detekcije kontaminacije govorom je znatno manji. Razlog za to može da se nađe u činjenici da je zašumljenost govorom izuzetno promenljivog karaktera, zbog različite dinamike govora i pauza u okviru rečenica, tako da je sasvim moguće da je primetna kontaminacija vidljiva samo u maloj količini snimljenih segmenata.

Druga dva algoritma koja vrše detekciju kontaminacije se ponašaju i kao klasifika-

tori detektovanog šuma. Jedan je baziran na implementaciji Neyman-Pearson testa na QQ krive, dok drugi koristi kepstralne koeficijente i metodu nosećih vektora. Neyman-Pearson test je proveren na snimku sa dve realne kontaminacije među kojima impulsni poremećaj uspeva veoma dobro da detektuje i klasificuje, dok je kod gorovne kontaminacije procenat detekcije i klasifikacije znatno niži. Veliki ograničavajući faktor ovog pristupa je neophodnost procene raspodele verovatnoće svake kontaminacije koja treba da se klasificuje. Pristup baziran na metodi nosećih vektora je prilično relaksiraniji u tom smislu. On je testiran na 4 različite vrste veštački uvedenih kontaminacija za različite vrednosti odnosa signal-šum. U smislu detekcije kontaminacije ima izuzetno visok procenat tačne detekcije, ali po cenu visokog procenta lažnih alarma. Ovo je prihvatljivo ponašanje algoritma za predobradu s obzirom da je tačna detekcija kontaminacije mnogo značajnija od tačne detekcije nominalnog signala. Što se klasifikacije kontaminacije tiče, ona direktno zavisi od vrste šuma koji je korišćen, prvenstveno od prepoznatljivosti njegove spektralne karakteristike, međutim čak i kontaminaciju sa relativno ravnom spektralnom karakteristikom ovaj algoritam uspeva da detektuje sa tačnošću od preko 70%.

Posle eliminacije kontaminiranih snimaka, pročišćen signal treba da se iskoristi za detekciju stanja mašine. S tim ciljem predložena je jednostavna metoda za izdvajanje obeležja koja je primenljiva na ciklostacionarnim signalima rotacionih aktuatora. Naime, u okviru ove procedure se izdvajaju standardni statistički parametri signala u vremenskom domenu i amplitudu spektra signala na karakterističnim frekvencijama (u skladu sa dinamikom mašine) i njihovim višim harmonicima. Pretpostavka o ciklostacionarnosti je opravdana zato što su nestacionarni, kontaminirani snimci eliminisani u prethodnom koraku. Detektori stanja rotacionih aktuatora koriste izdvojena obeležja i, u tom cilju, predložene su i analizirane tri različite metode. Jedna koristi novu strukturu Bajesovih mreža za modelovanje dinamike merenja, dok druga dva koriste standardne metode prepoznavanja oblika (redukciju dimenzija i klasterizaciju) za procenu stanja. Sva tri algoritma su testirana na velikoj bazi akustičkih signala koji su snimani na ventilatorskom mlinu u periodu od nekoliko meseci i koji su obuhvatili sva stanja kroz koja prolaze radna kola unutar mlina: od zdravih do izuzetno istrošenih udarnih ploča.

Detekcija stanja korišćenjem Bajesovih mreža je predstavljena kao binarni problem klasifikacije (postoje samo dve klase) i predložena je jednostavna mreža koja modeluje uticaj realnih stanja elemenata mašine na trenutna merenja. Testiranjem ove metode dobijaju se rezultati koji verno oslikavaju realno stanje mašine, ali po cenu jako visoke računske kompleksnosti algoritma. Zbog velike prilagodljivosti Bajesovih mreža različitim problemima predložene su još dve kompleksnije strukture koje se mogu koristiti za detekciju stanja, za slučaj primene na procesima kod kojih velika složenost ne može da se

modelira jednostavnom mrežom.

Računska jednostavnost algoritama je veoma važna za implementaciju u industriji, tako da su, u cilju povećanja brzine izvršavanja i pojednostavljenja procedure obučavanja, predložena još dva algoritma za estimaciju stanja koristeći metode za prepoznavanje oblika. Prvi metod koristi redukciju dimenzija da smanji dimenzionalnost obeležja na dvodimenzionalni prostor, a metrika koja oslikava stanje sistema je kontinualnog tipa i predstavljena je statističkom distancicom izmerenog snimka od obučavajućeg skupa koji oslikava zdravo ponašanje mašine. Drugi metod koristi supraktivnu klasterizaciju da u višedimenzionom prostoru proceni centre klastera i implementira metriku u vidu odnosa euklidske distance merenih odbiraka i centara klastera. Ove metode su testirane na realnim signalima, a njihova izuzetno značajna osobina je kreiranje kontinualnih metrika koje u svakom trenutku mogu da procene tačno u kom stadijumu istrošenosti se nalazi mašina. Što se tiče performansi, obe ove metode imaju sličnu tačnost, ali je metoda bazirana na klasterizaciji računski nešto jednostavnija, dok je metoda redukcije dimenzija praktičnija za dvodimenzionalnu vizualizaciju promene stanja mašina.

Imajući u vidu predložene algoritme, kao rezultat ove disertacije može da se realizuje jedan kompleksan sistem za predobradu signala, izdvajanje obeležja i detekciju stanja rotacionih aktuatora korišćenjem akustičkih snimaka. Ovaj sistem je primenljiv u realnim industrijskim uslovima zato što je robustan na šum, može da se generalizuje na široku familiju različitih mašina, a nije računski kompleksan, tako da može da se implementira na jednostavnom mikrokontrolerskom uređaju. Time bi cena jednog ovakvog uređaja bila izuzetno niska, a primenljivost velika zbog mogućnosti prilagođenja na veliki broj različitih problema.

Dalja istraživanja mogu da obuhvataju proširenje primenljivosti algoritama za pretprocesiranje signala. Naime, uvođenjem mogućnosti klasifikacije kontaminacije otvara se prostor za primenu ovih algoritama za rešavanje problema analize scenarija i ambijentalnu analizu. Na taj način bi se omogućilo korišćenje jednog senzora ne samo za detekciju ponašanja neke mašine, već i za analizu događaja koji se dešavaju u blizini mesta gde je senzor postavljen. U cilju dobijanja potpune slike o dešavanjima u nekom postrojenju bilo bi potrebno postaviti više ovakvih uređaja i umrežiti ih, na sličan način na koji se to radi prilikom praćenja dešavanja u tehnologijama pametnih zgrada. Takođe, dobro bi bilo implementirati sve analizirane korake na jedinstveni hardverski uređaj i proveriti njegovu sposobnost detekcije stanja na različitim vrstama aktuatora.

Literatura

- [1] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, and B. Wu, *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Hoboken, NJ, USA: Wiley, 2006.
- [2] G. Hartl, “World Health Organization report explains the health impacts of the world’s worst-ever civil nuclear accident,” World Health Organization, 2006. [Online]. Available: <https://phys.org/news/2011-03-iaea-japan-nuclear-quake-wikileaks.html>
- [3] INSAG, “INSAG-7 the Chernobyl accident: Updating of INSAG-1,” International Atomic Energy Agency, 1992. [Online]. Available: http://www-pub.iaea.org/MTCD/publications/PDF/Pub913e_web.pdf
- [4] Phys, “IAEA warned Japan over nuclear quake risk: WikiLeaks,” 2011. [Online]. Available: <http://www.who.int/mediacentre/news/releases/2006/pr20/en/>
- [5] V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri, “A review of process fault detection and diagnosis,” *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 293 – 311, 2003.
- [6] S. J. Bailey, “From desktop to plant floor, a CRT is the control operators window on the process,” *Control Engineering*, vol. 31, no. 6, pp. 86 – 90, 1984.
- [7] R. K. Mobley, *An Introduction To Predictive Maintenance*, 2nd ed. Woburn, MA, USA: Butterworth-Heinemann, 2002.
- [8] N. S. Arunraj and J. Maiti, “Risk-based maintenance: Techniques and applications,” *Journal of Hazardous Materials*, vol. 142, no. 3, pp. 653 – 661, 2007.

- [9] F. I. Khan and M. R. Haddara, “Risk-based maintenance of ethylene oxide production facilities,” *Journal of Hazardous Materials*, vol. 108, no. 3, pp. 147 – 159, 2004.
- [10] R. Dekker, “Applications of maintenance optimization models: a review and analysis,” *Reliability Engineering & System Safety*, vol. 51, no. 3, pp. 229 – 240, 1996.
- [11] B. Dhillon, *Engineering Maintenance: A Modern Approach*. Boca Raton, FL, USA: Taylor & Francis, 2002.
- [12] B. K. N. Rao, *Handbook of condition monitoring*. Oxford, UK: Elsevier, 1996.
- [13] F. I. Khan and M. R. Haddara, “Risk-based maintenance (rbm): a new approach for process plant inspecton and maintenance,” *Process Safety Progress*, vol. 23, no. 4, pp. 252 – 265, 2004.
- [14] Y. Lei, J. Lin, Z. He, and M. J. Zuo, “A review on empirical mode decomposition in fault diagnosis of rotating machinery,” *Mechanical Systems and Signal Processing*, vol. 35, no. 1, pp. 108 – 126, 2013.
- [15] C. J. Li and H. Lee, “Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics,” *Mechanical Systems and Signal Processing*, vol. 19, no. 4, pp. 836 – 846, 2005.
- [16] C. H. Oppenheimer and K. A. Loparo, “Physically based diagnosis and prognosis of cracked rotor shafts,” in *Proc. SPIE*, vol. 4733, 2002, pp. 122 – 132.
- [17] S. Marble and B. P. Morton, “Predicting the remaining life of propulsion system bearings,” in *2006 IEEE Aerospace Conference*, 2006, pp. 8 –.
- [18] A. Heng, S. Zhang, A. C. Tan, and J. Mathew, “Rotating machinery prognostics: State of the art, challenges and opportunities,” *Mechanical Systems and Signal Processing*, vol. 23, no. 3, pp. 724 – 739, 2009.
- [19] J. Lee, “A systematic approach for developing and deploying advanced prognostics technologies and tools: methodology and applications,” in *Second World Congress on Engineering Asset Management*, Harrogate, UK, 2007, pp. 1195 – 1206.
- [20] D. G. Bostwick and H. B. Burke, “Prediction of individual patient outcome in cancer,” *Cancer*, vol. 91, no. S8, pp. 1643 – 1646, 2001.

- [21] M. Orchard, B. Wu, and G. Vachtsevanos, “A particle filtering framework for failure prognosis,” in *Proceedings of the World Tribology Congress*, vol. 3, Washington, DC, USA, 2005, pp. 883 – 884.
- [22] X. Zhang, R. Xu, C. Kwan, S. Y. Liang, Q. Xie, and L. Haynes, “An integrated approach to bearing fault diagnostics and prognostics,” in *Proceedings of the American Control Conference 2005*. Portland, OR, USA: IEEE, 2005, pp. 2750 – 2755.
- [23] S. Zhang, L. Ma, Y. Sun, and J. Mathew, “Asset health reliability estimation based on condition data,” in *Proceedings of the 2nd WCEAM and the 4th ICCM*. Harrogate, UK, 2007: Coxmoor Publishing Company, 2007.
- [24] H. Liu and L. Yu, “Toward integrating feature selection algorithms for classification and clustering,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 4, pp. 491 – 502, April 2005.
- [25] D. Goyal, A. Saini, S. Dhami, B. Pabla *et al.*, “Intelligent predictive maintenance of dynamic systems using condition monitoring and signal processing techniques-a review,” in *Advances in Computing, Communication, & Automation (ICACCA)(Spring), International Conference on*. IEEE, 2016, pp. 1–6.
- [26] M. J. Crocker, *Handbook of noise and vibration control*. Hoboken, NJ, USA: John Wiley & Sons, 2007.
- [27] C. Scheffer and P. Girdhar, *Practical machinery vibration analysis and predictive maintenance*, 2nd ed. Oxford, UK: Elsevier, 2004.
- [28] N. Tandon and A. Choudhury, “A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings,” *Tribology International*, vol. 32, no. 8, pp. 469 – 480, 1999.
- [29] C. S. Sunnersjö, “Varying compliance vibrations of rolling bearings,” *Journal of sound and vibration*, vol. 58, no. 3, pp. 363 – 373, 1978.
- [30] F. P. Wardle and S. Y. Poon, “Rolling bearing noise-cause and cure,” *Chartered mechanical engineer*, vol. 30, pp. 36 – 40, 1983.
- [31] P. Cawley and R. D. Adams, “The location of defects in structures from measurements of natural frequencies,” *The Journal of Strain Analysis for Engineering Design*, vol. 14, no. 2, pp. 49 – 57, 1979.

- [32] W. Zhou, T. G. Habetler, and R. G. Harley, “Bearing condition monitoring methods for electric machines: A general review,” in *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, Sept 2007, pp. 3 – 6.
- [33] I. Yamada, K. Masuda, and H. Mizutani, “Electromagnetic and acoustic emission associated with rock fracture,” *Physics of the Earth and Planetary Interiors*, vol. 57, no. 1-2, pp. 157 – 168, 1989.
- [34] R. Teti and U. L. Commare, “Cutting conditions and work material state identification through acoustic emission methods,” *CIRP Annals - Manufacturing Technology*, vol. 41, no. 1, pp. 89 – 92, 1992.
- [35] N. Baydar and A. Ball, “A comparative study of acoustic and vibration signals in detection of gear failures using Wigner-Ville distribution,” *Mechanical Systems and Signal Processing*, vol. 15, no. 6, pp. 1091 – 1107, 2001.
- [36] P. Henriquez, J. B. Alonso, M. A. Ferrer, and C. M. Travieso, “Review of automatic fault diagnosis systems using audio and vibration signals,” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 44, no. 5, pp. 642 – 652, May 2014.
- [37] R. Tafreshi, “Feature extraction using wavelet analysis with application to machine fault diagnosis,” Ph.D. dissertation, The University of British Columbia, 2005.
- [38] D. R. Raichel, *The Science and Applications of Acoustics*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.
- [39] J. W. S. Rayleigh and R. B. Lindsay, *The Theory of Sound*, 2nd ed. New York, NY, USA: Dover Publications, 1945.
- [40] R. B. Lindsey, “Lindsay’s wheel of acoustics,” *The Journal of the Acoustical Society of America*, vol. 36, p. 2242, 1964.
- [41] F. A. Everest, *Master handbook of acoustics*, 4th ed. The McGraw-Hill, 2001.
- [42] R. Teti, K. Jemielniak, G. O’Donnell, and D. Dornfeld, “Advanced monitoring of machining operations,” *CIRP Annals - Manufacturing Technology*, vol. 59, no. 2, pp. 717 – 739, 2010.
- [43] B. Sick, “On-line and indirect tool wear monitoring in turning with artificial neural networks: A review of more than a decade of research,” *Mechanical Systems and Signal Processing*, vol. 16, no. 4, pp. 487 – 546, 2002.

- [44] K. Jemielniak and O. Otman, “Catastrophic tool failure detection based on acoustic emission signal analysis,” *CIRP Annals - Manufacturing Technology*, vol. 47, no. 1, pp. 31 – 34, 1998.
- [45] N. Ambhore, D. Kamble, S. Chinchanikar, and V. Wayal, “Tool condition monitoring system: A review,” *Materials Today: Proceedings*, vol. 2, no. 4, pp. 3419 – 3428, 2015, 4th International Conference on Materials Processing and Characterization.
- [46] L. Cohen, *Time-frequency Analysis: Theory and Applications*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1995.
- [47] B. Boashash, “Estimating and interpreting the instantaneous frequency of a signal. I. fundamentals,” *Proceedings of the IEEE*, vol. 80, no. 4, pp. 540 – 568, 1992.
- [48] J. B. J. Fourier, *The Analytical Theory of Heat*, ser. Cambridge Library Collection - Mathematics. Cambridge University Press, 2009.
- [49] A. Jha, “The Fourier transform lets you have your cake and understand it,” 2014, Datum pristupa stranici: 12.08.2017. [Online]. Available: <https://www.theguardian.com/science/2014/jul/13/fourier-transform-maths-equations-history>
- [50] R. C. Dixon, *Spread spectrum systems: with commercial applications*. Wiley New York, 1994, vol. 994.
- [51] X. Li, “A brief review: acoustic emission method for tool wear monitoring during turning,” *International Journal of Machine Tools and Manufacture*, vol. 42, no. 2, pp. 157 – 165, 2002.
- [52] B. P. Bogert, “The quefrency alalysis of time series for echoes: Cepstrum pseudo-autocovariance, cross-cepstrum, and saphe cracking,” *Time series analysis*, pp. 209 – 243, 1963.
- [53] R. B. Randall, “A history of cepstrum analysis and its application to mechanical problems,” *Mechanical Systems and Signal Processing*, vol. 97, pp. 3 – 19, 2017.
- [54] N. Ahmed, T. Natarajan, and K. R. Rao, “Discrete cosine transform,” *IEEE transactions on Computers*, vol. 100, no. 1, pp. 90 – 93, 1974.
- [55] L. Cohen, “Time-frequency distributions-a review,” *Proceedings of the IEEE*, vol. 77, no. 7, pp. 941–981, 1989.

- [56] P. Busch, T. Heinonen, and P. Lahti, “Heisenberg’s uncertainty principle,” *Physics Reports*, vol. 452, no. 6, pp. 155 – 176, 2007.
- [57] A. Papoulis, *Signal analysis*, ser. McGraw-Hill electrical and electronic engineering. McGraw-Hill, 1977.
- [58] D. Gabor, “Theory of communication. Part 1: The analysis of information,” *Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering*, vol. 93, no. 26, pp. 429 – 441, 1946.
- [59] D. Baccar and D. Soffker, “Wear detection by means of wavelet-based acoustic emission analysis,” *Mechanical Systems and Signal Processing*, vol. 60, pp. 198 – 207, 2015.
- [60] V. A. Pechenin, A. I. Khaimovich, A. I. Kondratiev, and M. A. Bolotov, “Method of controlling cutting tool wear based on signal analysis of acoustic emission for milling,” *Procedia Engineering*, vol. 176, pp. 246 – 252, 2017, proceedings of the 3rd International Conference on Dynamics and Vibroacoustics of Machines (DVM2016) June 29-July 01, 2016 Samara, Russia.
- [61] J. R. Williams and K. Amaratunga, “Introduction to wavelets in engineering,” *International journal for numerical methods in engineering*, vol. 37, no. 14, pp. 2365 – 2388, 1994.
- [62] Z. Su, P. Wang, X. Yu, and Z. Lv, “Experimental investigation of vibration signal of an industrial tubular ball mill: Monitoring and diagnosing,” *Minerals Engineering*, vol. 21, no. 10, pp. 699 – 710, 2008.
- [63] Z. K. Peng, P. W. Tse, and F. L. Chu, “An improved Hilbert–Huang transform and its application in vibration signal analysis,” *Journal of Sound and Vibration*, vol. 286, no. 1, pp. 187 – 205, 2005.
- [64] E. P. Wigner, “On the quantum correction for thermodynamic equilibrium,” *Physics Reviews*, vol. 40, pp. 749 – 760, 1932.
- [65] J. Ville, “Théorie et applications de la notion de signal analytique,” *Cables et transmission*, vol. 2, no. 1, pp. 61 – 74, 1948.
- [66] W. J. Wang and P. D. McFadden, “Early detection of gear failure by vibration analysis—i. calculation of the time-frequency distribution,” *Mechanical Systems and Signal Processing*, vol. 7, no. 3, pp. 193 – 203, 1993.

- [67] ——, “Early detection of gear failure by vibration analysis–ii. interpretation of the time-frequency distribution using image processing techniques,” *Mechanical Systems and Signal Processing*, vol. 7, no. 3, pp. 205 – 215, 1993.
- [68] A. Papacharalampopoulos, P. Stavropoulos, C. Doukas, P. Foteinopoulos, and G. Chryssolouris, “Acoustic emission signal through turning tools: A computational study,” *Procedia CIRP*, vol. 8, pp. 426 – 431, 2013.
- [69] A. Albarbar, F. Gu, A. Ball, and A. Starr, “Acoustic monitoring of engine fuel injection based on adaptive filtering techniques,” *Applied Acoustics*, vol. 71, no. 12, pp. 1132 – 1141, 2010.
- [70] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, “The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis,” in *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences*, vol. 454, no. 1971. The Royal Society, 1998, pp. 903 – 995.
- [71] G. Rilling, P. Flandrin, P. Goncalves *et al.*, “On empirical mode decomposition and its algorithms,” in *IEEE-EURASIP workshop on nonlinear signal and image processing*, vol. 3. IEEER, Grado, Italy, 2003, pp. 8 – 11.
- [72] Y. Wang, Q. Ma, Q. Zhu, X. Liu, and L. Zhao, “An intelligent approach for engine fault diagnosis based on Hilbert-Huang transform and support vector machine,” *Applied Acoustics*, vol. 75, no. 0, pp. 1 – 9, 2014.
- [73] E. Weller, H. M. Schrier, and B. Weichbrodt, “What sound can be expected from a worn tool?” *Journal of Engineering for Industry*, vol. 91, no. 3, pp. 525 – 534, 1969.
- [74] I. Grabec and P. Leskovar, “Acoustic emission of a cutting process,” *Ultrasonics*, vol. 15, no. 1, pp. 17 – 20, 1977.
- [75] D. Dyer and R. M. Stewart, “Detection of rolling element bearing damage by statistical vibration analysis,” *Journal of mechanical design*, vol. 100, no. 2, pp. 229 – 235, 1978.
- [76] S. Takata, J. H. Ahn, M. Miki, Y. Miyao, and T. Sata, “A sound monitoring system for fault detection of machine and machining states,” *CIRP Annals - Manufacturing Technology*, vol. 35, no. 1, pp. 289 – 292, 1986.

- [77] A. B. Sadat and S. Raman, “Detection of tool flank wear using acoustic signature analysis,” *Wear*, vol. 115, no. 3, pp. 265 – 272, 1987.
- [78] W. J. Staszewski and G. R. Tomlinson, “Local tooth fault detection in gearboxes using a moving window procedure,” *Mechanical Systems and Signal Processing*, vol. 11, no. 3, pp. 331 – 350, 1997.
- [79] N. Baydar and A. Ball, “Detection of gear failures via vibration and acoustic signals using wavelet transform,” *Mechanical Systems and Signal Processing*, vol. 17, no. 4, pp. 787 – 804, 2003.
- [80] D. Stowell, D. Giannoulis, E. Benetos, M. Lagrange, and M. D. Plumbley, “Detection and classification of acoustic scenes and events,” *IEEE Transactions on Multimedia*, vol. 17, no. 10, pp. 1733 – 1746, 2015.
- [81] Ž. Đurović and colleagues, *Dinamička regulacija kotla bloka TENT B1 posle uvođenja sistema DCS sa predlogom optimizacije procesa*. Elektrotehnički fakultet, Beograd, 2016.
- [82] M. E. Martellotti, “An analysis of the milling process,” *Transactions of the American Society of Mechanical Engineers*, vol. 63, no. 8, pp. 677 – 700, 1941.
- [83] V. Agrawal, B. K. Panigrahi, and P. M. V. Subbarao, “Review of control and fault diagnosis methods applied to coal mills,” *Journal of Process Control*, vol. 32, pp. 138 – 153, 2015.
- [84] J. Wang, J. Wei, and S. Guo, “Condition monitoring of power plant milling process using intelligent optimisation and model based techniques,” in *Fault Detection*, W. Zhang, Ed. InTech, 2010.
- [85] M. Kozic, S. Ristic, B. Katavic, and M. Puharic, “Redesign of impact plates of ventilation mill based on 3d numerical simulation of multiphase flow around a grinding wheel,” *Fuel Processing Technology*, vol. 106, no. 0, pp. 555 – 568, 2013.
- [86] T. Zivanovic, “Suggestions for calculation and construction of the fan mill barriershoop,” *FME Transactions*, vol. 30, no. 2, pp. 23 – 28, 2002.
- [87] J. Antoni, “Cyclostationarity by examples,” *Mechanical Systems and Signal Processing*, vol. 23, no. 4, pp. 987 – 1036, 2009.

- [88] R. Madani, J. Lavaei, R. Baldick, and A. Atamturk, “Power system state estimation and bad data detection by means of conic relaxation,” in *Proceedings of the 50th Hawaii International Conference on System Sciences*, 2017, pp. 3102 – 3111.
- [89] K. G. Borojeni, M. H. Amini, and S. S. Iyengar, “Bad data detection,” in *Smart Grids: Security and Privacy Issues*. Springer International Publishing, Cham, 2017, pp. 53 – 68.
- [90] W. Niemira, R. B. Bobba, P. Sauer, and W. H. Sanders, “Malicious data detection in state estimation leveraging system losses and estimation of perturbed parameters,” in *2013 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, Oct 2013, pp. 402 – 407.
- [91] S. Mishra, Y. Shoukry, N. Karamchandani, S. N. Diggavi, and P. Tabuada, “Secure state estimation against sensor attacks in the presence of noise,” *IEEE Transactions on Control of Network Systems*, vol. 4, no. 1, pp. 49 – 59, March 2017.
- [92] Y. Liu, P. Ning, and M. K. Reiter, “False data injection attacks against state estimation in electric power grids,” in *Proceedings of the 16th ACM Conference on Computer and Communications Security*, ser. CCS ’09. New York, NY, USA: ACM, 2009, pp. 21 – 32.
- [93] J. A. Zakis and C. M. Tan, “Robust wind noise detection,” in *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, May 2014, pp. 3655 – 3659.
- [94] J. J. Filliben, “The probability plot correlation coefficient test for normality,” *Technometrics*, vol. 17, no. 1, pp. 111 – 117, 1975.
- [95] R. Koenker, *Quantile Regression*. John Wiley & Sons, Ltd, 2006.
- [96] G. S. Kvascev, Z. M. Djurovic, and B. D. Kovacevic, “Adaptive recursive M-robust system parameter identification using the QQ-plot approach,” *IET Control Theory Applications*, vol. 5, no. 4, pp. 579 – 593, March 2011.
- [97] Z. Djurovic, B. Kovacevic, and V. Barroso, “QQ-plot based probability density function estimation,” in *Proceedings of the Tenth IEEE Workshop on Statistical Signal and Array Processing (Cat. No.00TH8496)*, 2000, pp. 243 – 247.

- [98] S. Vujnovic, A. Al-Hasaeri, P. Tadic, and G. Kvascev, “Acoustic noise detection for state estimation,” in *Proceedings of 3rd International Conference on Electrical, Electronic and Computing Engineering*, Zlatibor, Serbia, 2016, pp. 1 – 5.
- [99] S. Vujnovic, A. Marjanovic, Z. Djurovic, P. Tadic, and G. Kvascev, “Toward acoustic noise type detection based on QQ plot statistics,” *Facta Universitatis, Series: Electronics and Energetics*, vol. 30, no. 4, pp. 571 – 584, 2017.
- [100] S. Vujnovic, G. Kvascev, B. Kovacevic, and L. Cokic, “Acoustic noise detection and classification based on support vector machines,” in *Proceedings of 4th International Conference on Electrical, Electronic and Computing Engineering*, Kladovo, Serbia, 2017, pp. 1 – 5.
- [101] K. Fukunaga, *Introduction to Statistical Pattern Recognition*. San Diego, CA, USA: Academic Press Professional, Inc., 1990.
- [102] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. Academic Press, 2008.
- [103] G. Guo and S. Z. Li, “Content-based audio classification and retrieval by support vector machines,” *IEEE transactions on Neural Networks*, vol. 14, no. 1, pp. 209 – 215, 2003.
- [104] C. W. Hsu and C. J. Lin, “A comparison of methods for multiclass support vector machines,” *IEEE transactions on Neural Networks*, vol. 13, no. 2, pp. 415 – 425, 2002.
- [105] S. Nakamura, K. Hiyane, F. Asano, T. Nishiura, and T. Yamada, “Acoustical sound database in real environments for sound scene understanding and hands-free speech recognition.” in *LREC*, 2000.
- [106] J. Foote *et al.*, “Content-based retrieval of music and audio,” in *Proc. SPIE*, vol. 3229, 1997, pp. 138 – 147.
- [107] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine learning*, vol. 20, no. 3, pp. 273 – 297, 1995.
- [108] B. Wu, Z. Tian, and M. Chen, “Condition-based maintenance optimization using neural network-based health condition prediction,” *Quality and Reliability Engineering International*, vol. 29, no. 8, pp. 1151 – 1163, 2013.

- [109] N. D. Sims, G. Manson, and B. Mann, “Fuzzy stability analysis of regenerative chatter in milling,” *Journal of Sound and Vibration*, vol. 329, no. 8, pp. 1025 – 1041, 2010.
- [110] L. Lu, J. Yan, and C. W. de Silva, “Dominant feature selection for the fault diagnosis of rotary machines using modified genetic algorithm and empirical mode decomposition,” *Journal of Sound and Vibration*, vol. 344, no. 0, pp. 464 – 483, 2015.
- [111] S. Vujnovic, P. Todorov, Z. Djurovic, and A. Marjanovic, “The use of Bayesian networks in detecting the states of ventilation mills in power plants,” *Electronics*, vol. 18, no. 1, pp. 16 – 22, 2014.
- [112] S. Vujnovic, Z. Djurovic, and G. Kvascev, “Fan mill state estimation based on acoustic signature analysis,” *Control engineering practice*, vol. 57, pp. 29 – 38, 2016.
- [113] J. Pearl, “Bayesian networks: a model of self-activated memory for evidential reasoning,” *Proceedings of the 7th Conference of the Cognitive Science Society*, pp. 329 – 334, 1985.
- [114] S. Verron, J. Li, and T. Tiplica, “Fault detection and isolation of faults in a multivariate process with bayesian network,” *Journal of Process Control*, vol. 20, no. 8, pp. 902 – 911, 2010.
- [115] K. P. Murphy and S. Russell, “Dynamic Bayesian networks: representation, inference and learning,” 2002.
- [116] T. D. Nielsen and F. V. Jensen, *Bayesian networks and decision graphs*. Springer Science & Business Media, 2009.
- [117] Y. Zhao, F. Xiao, and S. Wang, “An intelligent chiller fault detection and diagnosis methodology using Bayesian belief network,” *Energy and Buildings*, vol. 57, pp. 278 – 288, 2013.
- [118] S. L. Chiu, “Fuzzy model identification based on cluster estimation,” *Journal of Intelligent & Fuzzy Systems*, vol. 2, no. 3, pp. 267 – 278, 1994.
- [119] J. S. R. Jang, C. T. Sun, and E. Mizutani, *Neuro-fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, ser. MATLAB curriculum series. Prentice Hall, 1997.

Biografija

Sanja Vujnović rođena je 30. aprila 1987. godine u Beogradu gde je završila osnovnu školu i Matematičku gimnaziju. Elektrotehnički fakultet Univerziteta u Beogradu je upisala 2006. godine. U junu 2010. godine je diplomirala sa prosekom 9.58 na Odseku za signale i sisteme. Master studije iz upravljanja procesima upisuje 2010. godine na univerzitetu *Imperial College* u Londonu, u trajanju od godinu dana, koje završava sa najvećom ocenom *Distinction*. Master rad joj se zvao "*Semidefinite relaxation for global optimization problems*" i rađen je pod supervizijom profesora Imad Jaimoukha. Doktorske studije na Elektrotehničkom fakultetu u Beogradu je upisala 2011. godine na modulu Upravljanje sistemima i obrada signala, a mentor doktorske teze joj je prof. dr Željko Đurović.

Sanja Vujnović je izabrana u zvanje asistenta u aprilu 2012. godine na Odseku za signale i sisteme. Trenutno je aktivno angažovana u držanju nastave na više predmeta iz oblasti automatskog upravljanja, obrade signala, stohastičkih sistema i induetrijske regulacije. U toku rada na fakultetu Sanja Vujnović je učestvovala na nekoliko projekata, među kojima su: TEMPUS projekat NeReLa, projekat bilateralne saradnje između Italije i Srbije RODEO, projekat Ministarstva za nauku i tehnološki razvoj,...

Oblast istraživanja Sanje Vujnović uključuje obradu signala, modeliranje i identifikaciju sistema, prepoznavanje oblika, detekciju i izolaciju otkaza. Među važnim istraživanjima može se svrstati detekcija stanja udarnih ploča mlinova u termoelektranama na osnovu akustičkih signala. Tokom leta 2013. godine bila je u studijskoj poseti na Univerzitetu u Kaliforniji, San Dijego (UCSD, *Cymer Center for Control Systems and Dynamics*) pod nadzorom profesora Miroslava Krstića, a 2013. i 2014. godine je poхађala kurseve Evropskog instituta za upravljanje (*European Embedded Control Institute, EECI*). Dosadašnji rezultati prikazani su kroz 1 rad u međunarodnom časopisu, 4 rada u domaćim časopisima, 6 radova na domaćim konferencijama i 11 radova na međunarodnim konferencijama.

Прилог 1.

Изјава о ауторству

Име и презиме аутора: Сања Вујновић

Број индекса: 2011/5023

Изјављујем

да је докторска дисертација под насловом:

Детекција стања ротационих актуатора заснована
на анализи акустичких сигнала

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршила ауторска права и користи³³ла интелектуалну својину других лица.

Потпис аутора

У Београду, 31.08.2017.



Прилог 2.

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: Сања Вујновић

Број индекса: 2011/5023

Студијски програм: Електротехника и рачунарство
(модул Управљање системима и обрада сигнала)

Наслов рада: Детекција стања ротационих актуатора заснована на
анализи акустичких сигнала

Ментор: проф. др Жељко Ђуровић

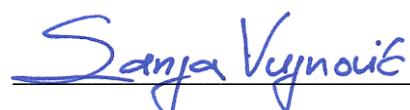
Изјављујем да је штампана верзија мого докторског рада истоветна електронској верзији коју сам предао/ла ради похрањења у **Дигиталном репозиторијуму Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис аутора

У Београду, 31.08.2017.



Sanja Vujošić

Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Детекција стања ротационих актуатора заснована
на анализи акустичких сигнала

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

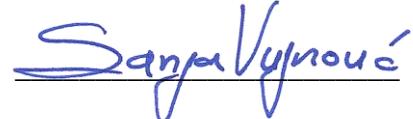
Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучила.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци.
Кратак опис лиценци је саставни део ове изјаве).

Потпис аутора

У Београду, 31.08.2017.



1. Ауторство. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

2. Ауторство – некомерцијално. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

3. Ауторство – некомерцијално – без прерада. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

4. Ауторство – некомерцијално – делити под истим условима. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

5. Ауторство – без прерада. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

6. Ауторство – делити под истим условима. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцима, односно лиценцима отвореног кода.