PRIMJENA DATA SCIENCE METODOLOGIJE U OTKRIVANJU UZORAKA IZ VREMENSKIH SERIJA

Jelić, Mario

Master's thesis / Specijalistički diplomski stručni

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Algebra University College / Visoko učilište Algebra**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:225:352167

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-18**

ALGEBRA VISOKO UČILIŠTE

Repository / Repozitorij:

Algebra Univerity College - Repository of Algebra Univerity College

zir.nsk.hr

dabar DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

VISOKO UČILIŠTE ALGEBRA

DIPLOMSKI RAD

PRIMJENA DATA SCIENCE METODOLOGIJE U OTKRIVANJU UZORAKA IZ VREMENSKIH SERIJA

Mario Jelić

Zagreb, veljača 2018.

Predgovor

Zahvali bih se Hrvatskom Telekomu i svojim direktorima Sandri Mikuš i Vjekoslavu Aleksić koji su mi omogućili ovo studiranje.

Posebna zahvala supruzi Korani i sinu Juriju na podršci i bezgraničnom strpljenju.

Prilikom uvezivanja rada, Umjesto ove stranice ne zaboravite umetnuti original potvrde o prihvaćanju teme diplomskog rada kojeg ste preuzeli u studentskoj referadi

Sažetak

Radom će se pokušati upotrijebiti REFII model nad binarnim audio zapisom, kako bi se dobio jedinstveni predložak pogodan za daljnju analizu. Rad je fokusiran na primjenu modela nad određenim podacima, u ovom slučaju audio zapisima. Fokusiran isključivo na istraživanje novog područja kako bi pokušali proširiti primjenu REFII modela, koji se čini pogodnim za primjenu nad audio zapisima. Osnovna tema rada je priprema podataka za upotrebu modela i upotreba modela nad podacima.

Ključne riječi: REFII, zvuk, frekvencija, Fourierova transformacija, normiranje.

The work will try to use a REFII model over the binary audio record to obtain a unique template suitable for further analysis. Work is focused on applying a model to specific data, in this case audio records. It is based on a new research area to try to extend the use of the REFII model, which seems to be suitable for audio tracking. The basic theme of work is to prepare data for using on model and data model usage.

Sadržaj

1. Uvod 1

2. Zvuk 3

2.1. Definicija zvuka 3

2.2. Frekvencija 3

2.3. Zvučni zapis 4

2.4. Digitalni zvučni zapis 4

2.5. Furierova transformacija 6

2.6. Prepoznavanje audio zapisa 8

2.7. Vremenska serija 9

3. REFII 11

4. Praktični primjer 14

4.1. Prikupljanja i spremanje binarnog zapisa sa audio kartice 14

4.2. Spremanje podatak u bazu, čišćenje, priprema za analizu 17

4.3. Implementacija REFII modela nad podacima, matematička obrada podataka 19

4.4. Stablo frekventnih uzoraka 39

Zaključak 43

Popis kratica 44

Popis slika 45

Popis tablica 46

Popis kôdova 47

Literatura 48

Prilog 50

1. Uvod

Motivacija za pisanje ove teme je prije svega u interesu za daljnjem razvojem znanja u pročuju rada s bazama podataka, zatim DWH i ponajviše analize dobivenih podataka, traženju logičnost i otkrivanju na prvi pogled nevidljivih veza i zakonitosti unutar istih. Inspiraciju za područje mogu prije svega zahvaliti profesoru Goran Klepac koji nam je dobro predočio što se sve može „skrivati“ u različitim vrstama podataka, kako do toga doći i koje zaključke iz toga izvući, te profesoru Robert Kopal koji nam je „otvorio oči“ objasnio i pokazao kako neke stvari možemo malo drugačije gledati i dobiti sasvim jednu drugu sliku iz koje opet možemo puno više vrijednog znanja izvući.

Motivacija i interes su dodatno potaknuti činjenicom da je riječ o području koje je novo i nudi zanimljiv istraživački rad, u konkretnom slučaju primjena REFII modela u svrhu otkrivanja uzoraka u vremenskim serijama.

Radom se pokušava dokazati da se pomoću REFII modela u analizi vremenskih serija može doći do konkretnih zaključaka i obrazaca na audio zapisima. Prvenstveno analiza je usmjerena na mogućnost primjene REFII modela na analitiku nad zvučnim zapisima, a samo primjena neće biti rađena na frekvencijskom opsegu audio zapisa već na vremenskim serijama unutar istih.

Pošto je REF II model prilično nov i inovativan pretpostavka je da će ovakva vrsta analize vremenskih serija pomoću navedenog modela pridonijeti proširenju iskustva rada s modelom te moguće otvoriti novo područja istraživanja na audio zapisima na ovaj način ili uputiti na slijepu ulicu. Audio zapisi su zapisivani u binarni oblik u određenom frekvencijskom opsegu i određenom količinom bajtova u jedinici vremena. Time smo dobili zapis u određenom vremenskom razmaku (vremenska serija). Osim toga, zapisivani su gustoćom od 0/10/50/100/1000 milisekundi pauze između zapisa, čime smo dobili različite zapise na istim podacima kako bi mogli napraviti usporedbu i potencijalno odlučiti koja gustoća zapisivanja je najbolja za ovakav tip podataka.

Koristit će se metode transformacije audio zapisa u vremenske serije. U ovom slučaju riječ je o Java aplikaciji koja čita sa ulaza zvučne kartice i zapisuje podatke u binarni zapis u određenom frekvencijskom opsegu i u određenom vremenskom razmaku. Podaci će biti

migrirani u Oracle bazu te će sva priprema nad podacima biti odrađena u PL SQL-u, kao i konverzija vremenskih serija u REFII model, prema tablicama konverzije koje će biti detaljno opisane u radu. U uvodnom dijelu praktičnog primjera osvrnut ćemo se i na drugi način analize, od kojeg se u prvoj fazi pripreme rada odustalo (iako je potrošeno puno vremena za savladavanje Phyton-a i na rad u PyChar-u na razini koja je bila potrebna) , a to je preko frekvencijskih opsega, a pomoću kojeg rade neke od postojećih aplikacija za prepoznavanje audio zapisa.

Praktični doprinos je novi pristup u analizi zvučnih zapisa pomoću REFII modela u svrhu otkrivanja uzoraka kod zvučnih zapisa.

Pokušati će se napraviti korak prema nekom novom načinu, tj. pristupu analizi audio zapisa kao vremenskoj seriji kroz modeliranje u REFII modelu, kroz koji se pak traže karakteristični uzorci.

Fokus neće biti na metodologiji rada REFII modela već na praktičnoj primjeni, zato je sam model opisan u osnovnim crtama.

Hipoteza

Radom će se pokušati dokazati da je moguće kvalitetno pripremiti podatke nastale audio zapisom za daljnju analizu pomoću REFII metodologije. Znači da audio zapis promatran kako vremenska serija možemo implementirati kroz REFII model i pripremiti za analizu nekim od već postojećih alata, kako bi mogli u njima otkriti potencijalne predloške i zakonitosti. Izazove će biti to napraviti na čim „sirovijim“ binarnim podacima.

2. Zvuk[1]

Kako bi mogli vidjeti gdje je razlika u načinu analize zvučnih zapisa, razmotrit ćemo što je zvučni zapis i što je frekvencijski opseg, kako radimo analitiku nad njime i koje su razlike s obzirom na tematiku kojoj ćemo se baviti u radu. Na početku ćemo definirati što je to zvuk i frekvencija, te na koji se način zvuk može zapisivati i kako se njime može manipulirati.

2.1. Definicija zvuka

Prema definiciji iz hrvatske enciklopedije zvuk je mehanički val frekvencija od 16 Hz do 20 kHz, tj. u rasponu u kojem ga čuje ljudsko uho. Zvuk frekvencije niže od 16 Hz naziva se infrazvukom, zvuk frekvencije više od 20 kHz ultrazvukom, a ako je frekvencija viša od 1GHz, hiperzvukom. Zvuk nastaje više ili manje periodičnim titranjem izvora zvuka koji u neposrednoj okolici mijenja tlak medija, poremećaj tlaka prenosi se na susjedne čestice medija i tako se širi u obliku uglavnom longitudinalnih valova u plinovima i kapljevinama i longitudinalnih i transverzalnih valova u krutinama.

2.2. Frekvencija

Frekvencija je fizikalna veličina koja iskazuje broj ponavljanja neke periodične pojave u jedinici vremena (periodično gibanje). Ljudsko je uho osjetljivo za zvuk u rasponu frekvencija od oko 16 Hz do 20 000 Hz. Hz, herc je mjerna jedinica frekvencije, što je poseban naziv za recipročnu sekundu (Hz = 1/s).

Slikoviti primjer frekvencije niže (donji valovi imaju veću frekvenciju od donjih).

[1] Za potrebe objašnjenje pojmova vezanih uz zvuk korištena je Hrvatska enciklopedija na WEB-u, točke pod Literatura [8],[9] i [10]

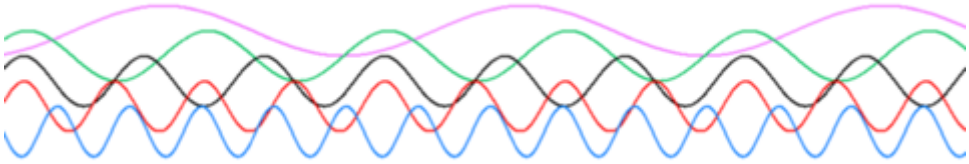

Slika 2.1 Frekvencija

2.3. Zvučni zapis

Kako je već navedeno, zvuk se sastoji od titraja koji putuju u obliku valova promjenjivog tlaka zraka. Mikrofon stvara kopiju tih titraja u obliku električnog zvučnog signala koji se može pohraniti na više različitih načina, uključujući neki medij za pohranu kao što su CD-i, magnetofonske vrpce ili gramofonske ploče. Razlikujemo analogne i digitalne nosače zvuka. Analogni nosači zvuka na sebi imaju valovite utore ili magnetske obrasce koji kopiraju promjene u analognom zvučnom signalu. Digitalni nosači zvuka sadrže informacije o digitalnom zvučnom signalu u binarnom kodu, u obliku magnetskih obrazaca ili niza sićušnih rupica. Gramofonska ploča i magnetna traka su primjeri analognih nosača, dok su DAT trake, CD-i primjeri digitalnih nosača zvuka. Digitalno se zvuk može pohraniti i na hard disku na računalu tako da se u zvučnoj kartici analogni signal pretvara u digitalni. Podaci se na računalu mogu i sažimati u neki od mnogih audio formata kako bi bilo jednostavnije manipulirati njima.

2.4. Digitalni zvučni zapis

Zvuk se sastoji od titraja koji putuju u obliku valova promjenjivog tlaka zraka određene frekvencije. Kad te vibracije dođu do našeg uha prenosi se do bubnjića i izazivaju titranje, dalje se titranje prenosi do pužnice u unutarnjem uhu što pak izaziva pomicanje tekućine i titranje membrane, koji će se preko Cortijeva slušnog aparata pretvoriti u živčane impulse i doći do mozga.

Može se reći da će i na sličan način mikrofon stvoriti kopiju tih titraja iz zraka u oblik električnog zvučnog signala, koji se može pohraniti na više različitih načina. Pohranjeni

signal može biti izravan prikaz originalnog zvuka, analogno snimanje. Taj neprekinuti zapis toka signala u ovom radu nam nije zanimljiv jer nije upotrebljiv te ga je najprije potrebno pretvoriti u takozvani diskretni vremenski signal koji se može spremiti u digitalnom obliku. To se može napraviti na način da se „ulovi“ digitalna vrijednost koja predstavlja amplitudu signala u određenom trenutku.

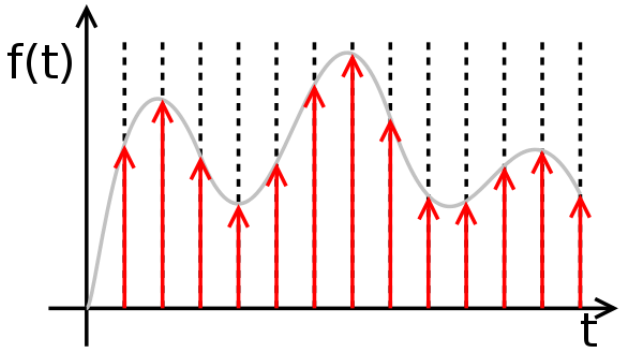

Slika 2.2 Amplituda signala

To je upravo onaj zapis koji je potreban kako bi dalje se mogli baviti analizom zvučnog zapisa.

Pretvorba uključuje kvantizaciju ulaznih podataka i nužno uvodi malu količinu pogreške. Stoga, umjesto jedne pretvorbe, analogno-digitalni pretvarač obavlja mnogo pretvorbi na vrlo malim dijelovima signala.

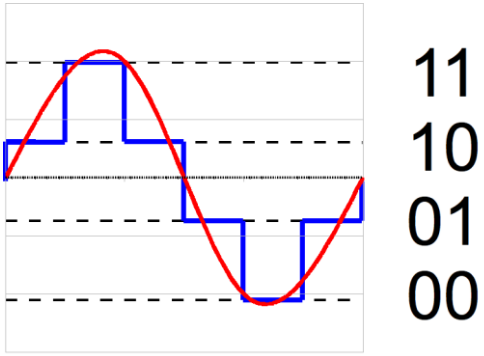

Slika 2.3 Analogno – digitalni pretvarač

Kasnije će se u praktičnom primjeru vidjeti koji frekvencijski opseg će se snimati i pretvarati u digitalni oblik i s kojom brzinom uzrokovanja.

Nakon što je zvučni zapis digitalno „ulovljen“, u datoteci on izgleda kao na slici 2.4. Znači niz brojeva, originalno bajtova (nula i jedinica) koji su odmah pretvoreni u dekadske brojeve, prije zapisivanja u datoteku, kako bi bilo lakše raditi s njima.

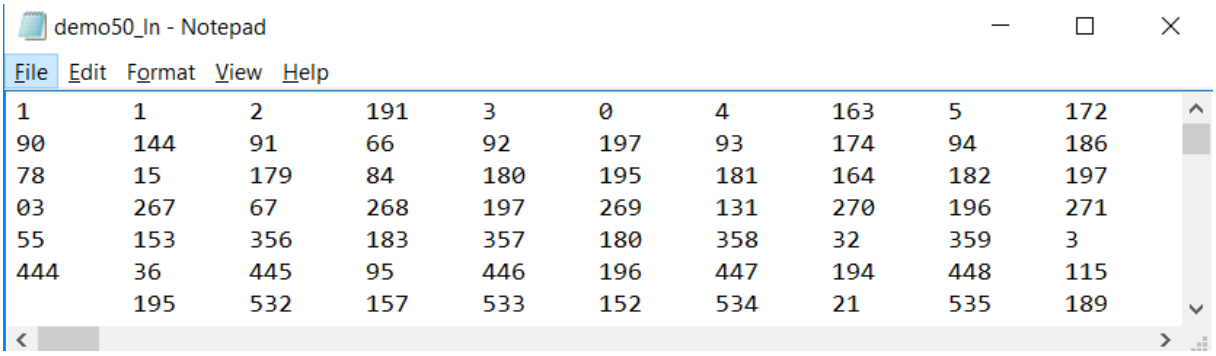

Slika 2.4 Binarni zapisa audio signala

2.5. Furierova transformacija [2]

Ono što je dobiveno je zapis u određenoj vrsti vremenske serije, dakle promjena amplitude signala tijekom vremena. Naime, osim brojeva koje imamo u datoteci, oni su zapisanu u određenom vremenskom rasponu, takozvani *sample rate*, u ovom slučaju on je 16 bajta. Znači zapis jednog bajta je svakih 16 bajta.

Svaki signal u vremenskoj domeni je ekvivalentan zbroju nekog (možda beskonačnog) broja jednostavnih sinusoidnih signala, budući da svaka sinusoidna komponenta ima određenu frekvenciju, amplitudu i faze. Niz sinusoida koji zajedno tvore izvorni signal vremenske domene poznat je kao Fourierov niz prema Jean-Baptiste Joseph Fourier-u koji ga je otkrio.

Kako bi signal iz vremenske domene pretvorili u takvu frekvencijsku domenu treba nam diskretna Furierova transformacija što je matematička metodologija konverzije signala.

[2] Za potrebe objašnjenje pojmova vezanih uz Furierovu transformaciju, kao i pojmova o prepoznavanju audio zapisa korišteni su materijali pod Literatura [6]

Ona pretvara konačan popis jednako razmaknutih uzoraka funkcije u popis koeficijenata konačne kombinacije složenih sinusoida, određenih njihovim frekvencijama, uzimajući u obzir da li su ti sinusoidi uzorkovani isto brzinom.

Korkretan izlaz izgleda kao na slici niže. Znači,digitalni zapis, koji je snimljen u određenom trajanju se pretvara u zapis frekfencijskih opsega.

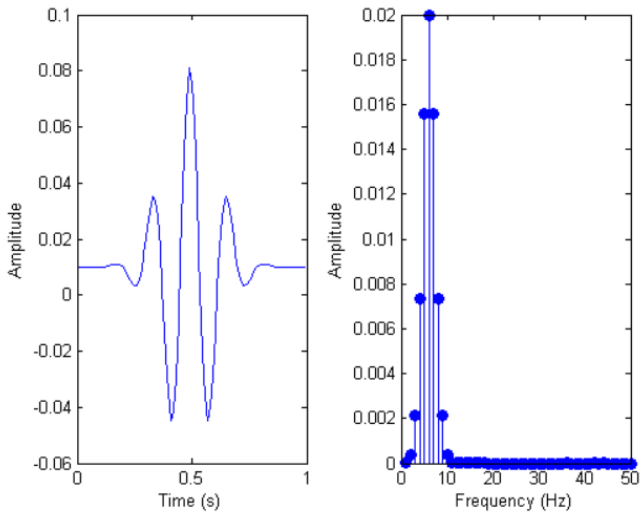

Slika 2.5 Digitalni zapis (lijevo) i njegov zapis u frekvencijskom opsegu (desno)

Niže je detaljniji opis koverzije.

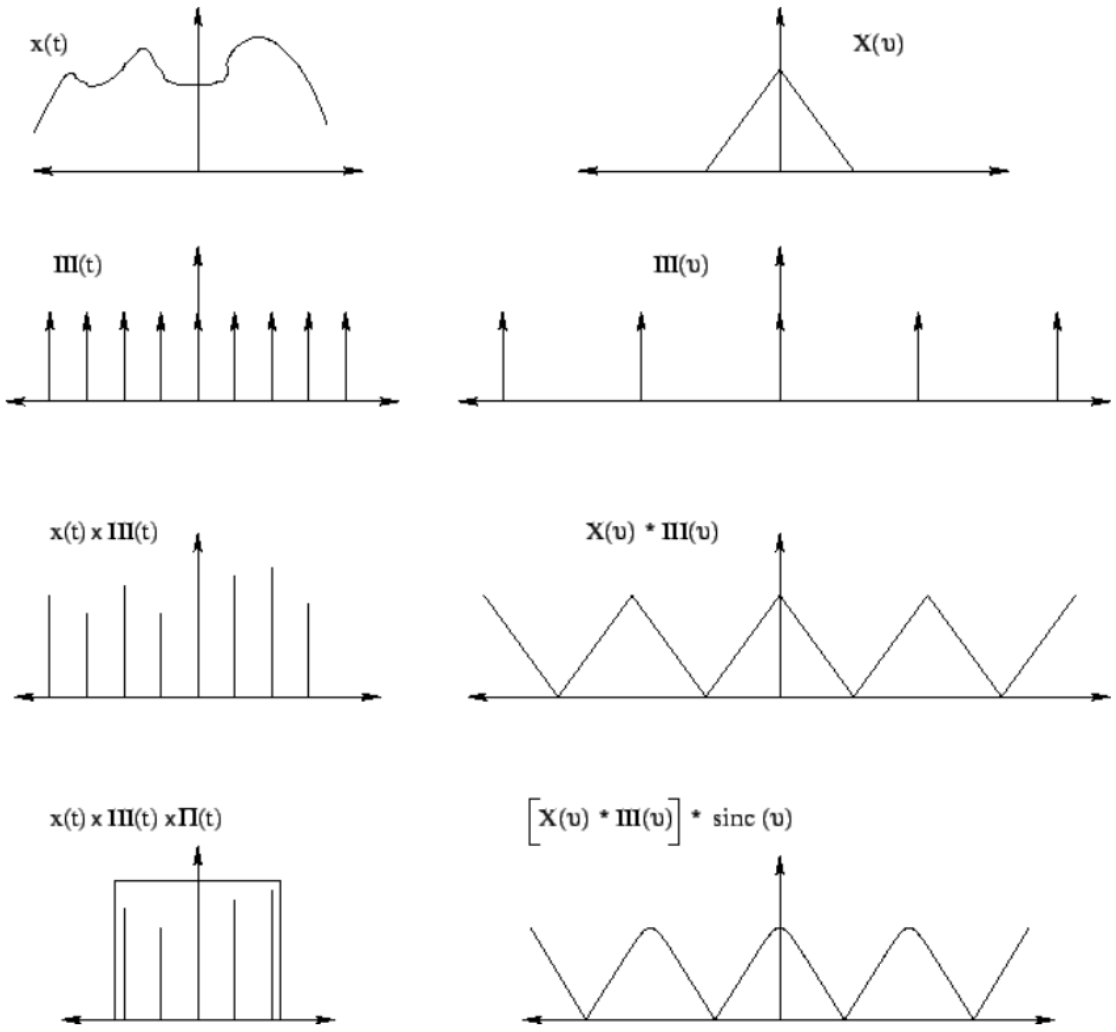

Slika 2.6 Opis konverzije digitalnog zapisa

Najpoznatiji algoritam je Fast Fourier transform (FFT) koji ima više varijacija, a najkorištenija varijacija je Cooley–Tukey algoritam. Sada već postoji mnogo gotovih implementacija algoritma kojeg je samo potrebno ugraditi u aplikaciju kako bi se konvertiralo zapis.

2.6. Prepoznavanje audio zapisa

Ono što sad rade aplikacije za prepoznavanje audio zapisa, nakon što su odradili Fourierovu transformacijom je kreiranje jedinstvenog potpisa pjesme, na način da iz cijelog frekvencijskog opsega izvuku one s najvećom magnitudom, ali i unutar njih samo manje intervale koji se nalaze u uobičajenim frekvencijskim opsezima muzičkih dijela.

Recimo dio za pokrivanje niskih (na primjer 30 Hz - 40 Hz) i dio za pokrivanje visokih tonova (na primjer 120 Hz - 180 Hz). Sada unutar svakog od tih intervala se izvlače frekvencije s najvećom magnitudom. Te vrijednosti čine dio jedinstvenog potpisa pjesme.

Ali ono što je generalni problem kod FFT-a, je gubitak podatka o vremenu, odnosno vremenskoj dimenziji, dakle imamo frekvencijski opseg i podatke, ali ne znamo kad se pojavljuju i koliko traju.

To je bio jedan od razloga zašto je ubrzo nakon pokušaja s Fourierovom transformacijom odabrana primarno vremenska serija kao format podatka za analizu a ne podatke dobivene Fourierovom transformacijom, no o tome detaljnije kasnije u samom radu. Vratimo se sada, prije praktičnih primjera, na još neke pojmove koji su bitni.

2.7. Vremenska serija

Vremenska serija je skup podatka o određenom vremenskom intervalu i podatka za koji se prati promjena u tom intervalu. Taj interval je poredan kronološkim redoslijedom u jednakim vremenskim odsječcima. Zato je vrlo bitno normiranje vremenskih serija u slučaju da ista nije u jednakim vremenskim odsječcima, što kod nas neće biti problem i s te strane nema potrebe za normiranjem i predprocesiranjem tog dijela. No zbog prirode digitalnog signala, odnosno digitalnog zapisa postoji potrebe za granulacijom vremenske serije. Koja je opisana niže u praktičnom primjeru.

Glavni postupci analize vremenskih serija u ovom slučaju, su:

- analiza cikličkih pojava unutar serije
- pronalaženje sličnosti uzoraka unutar serije
- pronalaženje i otklanjanje irelevantnih sekvenci iz serija
- analiza korelacijskih odnosa, kako između vremenskih serija tako i njezinih odsječaka
- analiza sličnosti vremenskih serija

Također kao bitnu metodu treba spomenuti metodu vizualizacije, kako bi predočili karakteristike određenog segmenta serije.

Prije svega u ovom radu glavni pristup analizi bila je svakako analiza cikličkih pojava unutar serije, što je mogli bi reći logički svojstvena metoda muzičkom zapisu. Upravo najkorištenija metodologija takve vrste analize je Fourierova transformacija o kojoj je već

bilo riječi, kao i o problemu koji se pojavljuje zbog gubitka određenih podataka, konkretno u našem primjeru vremenske dimenzije.

Upravo iz tih razloga odabran je REFII model kao jedinstveni model transformacije vremenske serije, kako bi se pronašle cikličke pojave unutar serije.

3. REFII [3]

REFII, akronim od engl. *Raise-Equal-Fall* u prijevodu Raste-Stagnira-Opada te verzije modela (druga verzija). Autor REFII modela je dr.sc. Goran Klepac, i ovaj je model razrađen u sklopu njegove doktorske disertacije. Model se oslanja na jedinstveni model transformacije vremenske serije i omogućuje integraciju više analitičkih postupaka nad vremenskom serijom, što mu je velika prednost nad postojećim metodama, jer se zanemarivala važnost transformacije, a što je ključ REFII modela. Nakon transformacije analizu vremenske serije moguće je napraviti pomoću tradicionalnih metoda.

Tradicionalne metode koje se bave analizom vremenskih serija imaju svaka svoj model transformacije koji su prilagođeni problematici kojoj se bave, dok je upravo prednost REFII modela u tome da se manifestira u modelu transformacije kao osnovi analize, što je onda temelj za analizu nekom od metoda.

Znači da kada postoji jednoznačan model transformacije nad vremenskim serijama ili njezinim segmentima, moguće je uspoređivati međusobno serije ili odsječke vrlo djelotvorno što je velika prednost i fleksibilnost, a nad takvim podacima možemo upotrebljavati tradicionalne metode za analizu.

Tri su osnovna segmenta REFII modela:

- oblik krivulje (opis izgleda vremenske serije)
- površina ispod krivulje (kvantifikacija vremenske serije)
- koeficijent kutnog nagiba pravca unutar vremenskog odsječka ("jačina" trenda).
- Transformacija mora obuhvatiti sva tri segmenta modela, a odvija se u nekoliko koraka.
- Vremensku seriju možemo deklarirati kao niz vrijednosti S(s1,..,sn), gdje S predstavlja
- vremensku seriju, a (s1,..,sn) elemente serije S.

Koraci

[3] Za potrebe objašnjenje pojmova vezanih uz REFII model, objašnjenje rada modela, metodologiju modela, formule za transformaciju, korišten je doktorski rad profesora Goran Klepac, kao i dijelovi rada, te pojmovi i dijelovi iz knjige Poslovna inteligencija, kao i sa službene stranice profesora www.goranklepac.com, pod Literatura [1], [2], [7], kao pomoć u ideji provedbe upotrebe modela korišten je doktorski rad profesora Leo Mršić, pod Literatura [3]

- Vremenska interpolacija
  Formiranje samostalnog vremenskog niza Vi na intervalu <1..n> (Dani, tjedni, mjeseci, kvartali, godine) sa vrijednostima 0. Na temelju tako formiranog niza potrebno je provesti interpolaciju nedostajućih vrijednosti u Vs-u sa 0 na temelju formiranog niza Vi. Rezultat ovakve obrade je niz Vs sa interpoliranim vrijednostima niza Vi
- Vremenska granulacija
  Na taj način vremensku seriju se može svesti na veći stupanj granulacije (dani u tjedne, tjedni u mjesece ...)
- Normiranje
  Postupak normiranja podrazumijeva transformaciju vremenske serije Vg u Ns pri čemu je svaki element niza podvrgnut postupku min-max normizacije na intervalu <0,1> i to
  Ns (Y1,.., Yn)=((Xi- min(Vs))/(max(Vs)-min(Vs))
  mjerilo vremenske kompleksnosti odsjecka na X osi d(Yi,Yi+1)=0.1
- Transformacija u REF notaciju
  Prema formuli Tr=Yi+1- Yi Tr > 0 =>R; Tr< 0 =>F; Tr=0 =>E , gdje su Yi elementi niza Ns
- Proračun nagiba pravca na osnovu kuta
  Koeficijent katnog otklona=>
  Tr > 0 (R) Koeficijent =y2-y1
  Tr < 0 (F) Koeficijent =y1-y2
  Tr = 0 (E) Koeficijent = 0
  gdje su gdje su Yi elementi niza Ns

- Proračun Površine ispod krivulje
  Numerička integracija metodom pravokutnika
  p= ((y1*0.1)+(y2*0.1))/2
  gdje su gdje su Yi elementi niza Ns

- Kreiranje vremenskih indeksa
  Građenje hijerarhijskog stabla indeksa ovisno o karakteru analize, gdje element strukturiranog indeksa može biti i atribut poput šifra klijenta
- Kreiranje razreda
  Kreiranje izvedenih vrijednosti atributa na temelju površine ispod krivulje i otklona kutova

- Povezivanje tablice transformacije REFII modela sa relacijskim tablicama koje sadrže atribute koji nemaju vremensku dimenziju

Ovih devet osnovnih koraka temelj su algoritmiziranog postupka na kojem se temelji REFII model. Cilj je krajnji rezultat formiranje matrice transformacije. Matrica

transformacije je temelj za provođenje daljnjih analitičkih postupaka s ciljem analize vremenske serije.

Zbog karakteristika početnog seta podataka ili specifične vrste analize ponekad nije potrebno proći sve korake, što je detaljnije prikazano u na praktičnim primjerima.

4. Praktični primjer[4]

Konkretno, za snimanje svih frekvencija koje čovjek može čuti u audio signalu, moramo uzorkovati signal na frekvenciji dvostruko većoj od raspona ljudskog raspona. Ljudsko uho može otkriti frekvencije otprilike između 20 Hz i 20 000 Hz. Kao rezultat toga, zvuk je najčešće zabilježen pri brzini uzorkovanja od 44.100 Hz. To je brzina uzorkovanja Compact diskova, a također je najčešće korištena brzina s MPEG-1 audio kompresijom. Dakle, frekvencija koju je potrebno snimiti je 44.100 Hz.

4.1. Prikupljanja i spremanje binarnog zapisa sa audio kartice

Audio zapisi zapisani u binarnom obliku su jako velike datoteke, koje kao takve zahtijevaju veliku potrošnju procesorskog vremena, kao i mjesta za skladištenje u bazama podataka. Zato je dodatno bitno kojom gustoćom će se upisivati podatci i da li je potreban baš svaki bajt. Za početak to će biti 16 bajta (sample rate).

```
        private static AudioFormat getFormat() {
            float sampleRate = 44100;
            int sampleSizeInBits = 16;
            int channels = 1;
            boolean signed = true;
            boolean bigEndian = true;
            return new AudioFormat(sampleRate,
sampleSizeInBits, channels, signed, bigEndian);

        }
```

Kod 4.1 Definicija samle rate-a

[4] Za potrebe izrade ideje rješenja aplikacije korišteni su izvori , kao i njihovi dijelovi, pod Literatura [4], [5], [6]

Prvi izazov je bio kako doći do podataka za analizu. Na WEB –u ima dosta materijala u raznim zapisima kao i dosta već pripremljenih podataka u tablicama. Odlučeno je se krene ispočetka, te da se napravi aplikacija koja će zapisati ulazne podatke sa zvučne kartice u datoteku.

Razlog zašto je to napravljeno u Javi je što na Internetu ima više primjera kako to napraviti.

Odluka je da se koristi TargetDataLine:

```
      DataLine.Info info = new
DataLine.Info(TargetDataLine.class, format);
                  line = (TargetDataLine)
AudioSystem.getLine(info);
               line.open(format);
                 line.start();
```

Kod 4.2 TargetDataLine

te zapiše podatke u datoteku, ali prije toga pretvori u binarni zapis, koji je prihvatljiviji za obradu:

```
      public static void printBytes(byte[] array, String
name) throws IOException, InterruptedException {

            FileWriter fr = new
FileWriter("C:\\Users\\mjelic\\Desktop\\demo100.txt");
            bf = new BufferedWriter(fr);

          for (int k = 0; k < array.length; k++) {
              bf.write(

      "\n"+hex2decimal(UnicodeFormatter.byteToHex(array[k]).t
oString())+"\t"
                          );

              k = k+100;
          }
      };
```

```
    public static int hex2decimal(String s) {
      String digits = "0123456789ABCDEF";
      s = s.toUpperCase();
      int val = 0;
      for (int i = 0; i < s.length(); i++) {
          char c = s.charAt(i);
          int d = digits.indexOf(c);
          val = 16*val + d;
      }
      return val;
  };
        public static    String byteToHex(byte b) {
              char hexDigit[] = {
                 '0', '1', '2', '3', '4', '5', '6', '7',
                 '8', '9', 'a', 'b', 'c', 'd', 'e', 'f'
              };
              char[] array = { hexDigit[(b >> 4) & 0x0f],
hexDigit[b & 0x0f] };
              return new String(array);
           }
```

Kod 4.3 Upis u datoteku

Datoteka koju pritom dobijemo izgleda ovako:

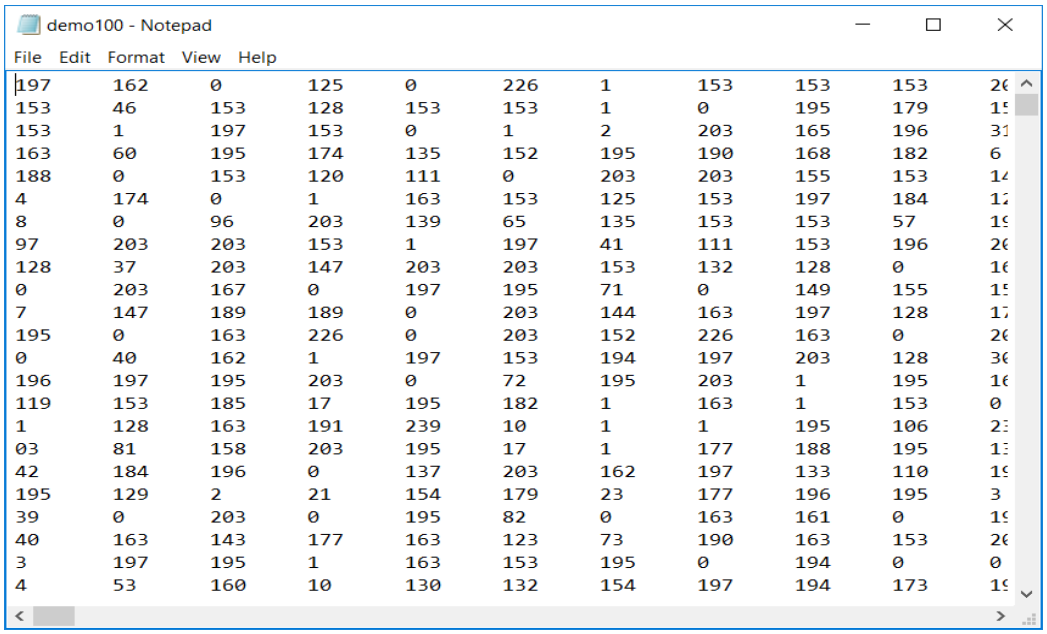

Slika 4.1 Izgled datoteke binarnog zapisa

Kako je prva ideja bila pokušati podatke pretvoriti u frekvencijski opseg i tada napraviti neku analitiku, nad istima je bilo potrebno napraviti fourierovu transformaciju.

Kako algoritam za fourierovu transformaciju konvertira skup kompleksnih brojeva u drugi skup istih, ove brojeve treba pretvoriti u kompleksne. Najjednostavnije je da se broj iz datoteke definira kao realni dio a doda nula kao imaginarni dio broja. Znači ono što se dobije je skup kompleksnih brojeva, ali ono što se izgubi je pojam o vremenskim dimenzijama, što nikako ne odgovara za vrstu analize koju želimo napraviti. Zato je ubrzo odluka donesena da ne koristi frekvencijski opseg.

4.2. Spremanje podatak u bazu, čišćenje, priprema za analizu

Podatke iz datoteke je najprije trebalo pripremiti za analizu.

Kako je podatak zapisan u sample rate-u od 16 bajta, najprije je u .csv datoteku dodana uz svaku vrijednost i sample rate :

sample rate	value
16	226
32	128
48	148
64	9
80	197
96	185
112	8
128	104
144	8
160	99

Tablica 4.1: Prikaz vrijednosti po sample-u

A kada su podatci migrirani u Oracle bazu umjesto sample rate-a stavljeni su redni brojevi (jer znamo da je sample rate 16) .

Početna verzija je prikazana u tablici 3.2. “ Prikaz vrijednosti po sample-u u bazi“. Vizualni prikaz i prikazan na slici 4.2. „vrijednost audio zapisa u vremenskim razmacima“

ID	BAJT
1	153
2	203
3	153
4	203
5	153
6	0
7	0
8	203
9	153

Tablica 4.2: Prikaz vrijednosti po sample-u u bazi

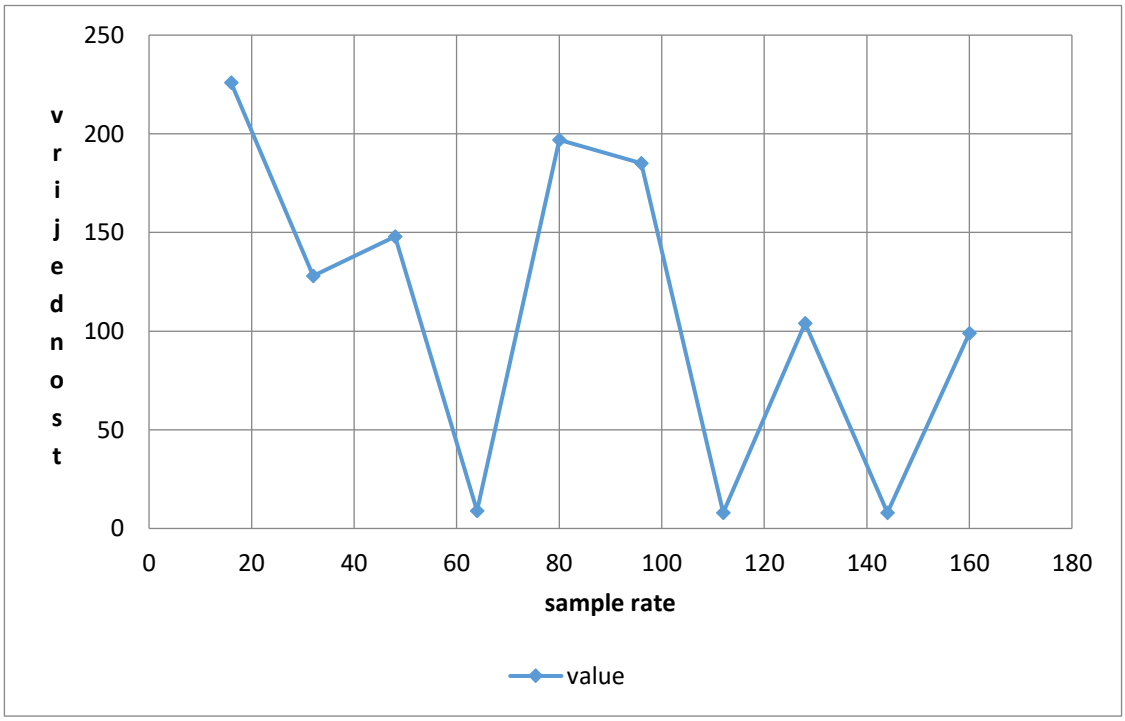

Slika 4.2 vrijednost audio zapisa u vremenskim razmacima

Dobivena je nepregledna krivulja digitalnog zapisa audio signala zapisanog u određenim vremenskim razmacima. Kako su dobiveni podatci prilično neupotrebljivi za konkretniju analitiku, upotrijebljen je REFII model za obradu podataka kako bi od njih dobili upotrebljive informacije.

4.3. Implementacija REFII modela nad podacima, matematička obrada podataka

Prisjetimo se koraka za implementaciju modela. Prva dva koraka nam u ovom slučaju nisu potrebna (vremenska interpolacija i vremenska granulacija) jer imamo vremenski niz koji je već granuliran na 16 bajta u ovom slučaju.

Treći korak je normiranje gdje za svaki element niza treba napraviti min-max normizacije na intervalu <0,1> .

Formula za normiranje:

$$x_normirano = \frac{x_nenormirano - x_min}{x_max - x_min} \quad (1)$$

Gdje je :
x_normirano - normirana vrijednost (u intervalu između 0 i 1)
x_nenormirano- vrijednost koja se normira
x_max – maksimalna vrijednost promatrane vremenske serije
x_min – minimalna vrijednost promatrane vremenske serije

Vrlo jednostavno to izračunamo u PL / SQL-u:

```
begin
```

```
for rst in(
select id, bajt,(bajt - (select min(bajt) from
refii))/((select max(bajt) from refii)-(select min(bajt) from
refii)) x_normirano_  from refii)
loop
update refii set X_NORMIRANO = rst.x_normirano_ where id =
rst.id;
end loop;
end;
```

Kod 4.4 Izračun normizacije

Data Grid

Messages | Data Grid | Auto Trace | DBMS Output (disabled) | Query Viewer | Explain Plan | Script Output

	ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON
▶	1728	22	0,0920502092050209		
	1729	195	0,815899581589958		
	1730	188	0,786610878661088		
	1731	41	0,171548117154812		
	1732	2	0,00836820083682008		
	1733	45	0,188284518828452		
	1734	5	0,0209205020920502		
	1735	197	0,824267782426778		
	1736	159	0,665271966527197		
	1737	195	0,815899581589958		
	1738	188	0,786610878661088		

Slika 4.3 Prikaz normiranih vrijednosti u bazi

Slijedeći korak za implementaciju modela je izračun kutnog otklona za koji sada imamo informaciju. Kutni otklon se računa prema formuli:

$$\frac{dx}{dt} = \left|x_normirano_t - x_normirano_{t-1}\right| \quad (2)$$

Gdje je:

x_normirano_t – podatak kojeg smo izračunali prilikom normiranja

x_normirano_t-1 - podatak koji slijedi iza x_normirano_t

Isto je odrađeno u PL/SQL-u:

```
declare
```

```
znakovi number;
i NUMBER DEFAULT 1;
begin
select max(id)  into znakovi from refii;
for i in 1..znakovi
loop
update refii set DX_DT = (select((select X_NORMIRANO  from
refii where id = i)-(select X_NORMIRANO from refii where id =
i+1))from dual) where id = i;
commit;
end loop;
end;
```

Kod 4.5 Izračun kutnog otklona

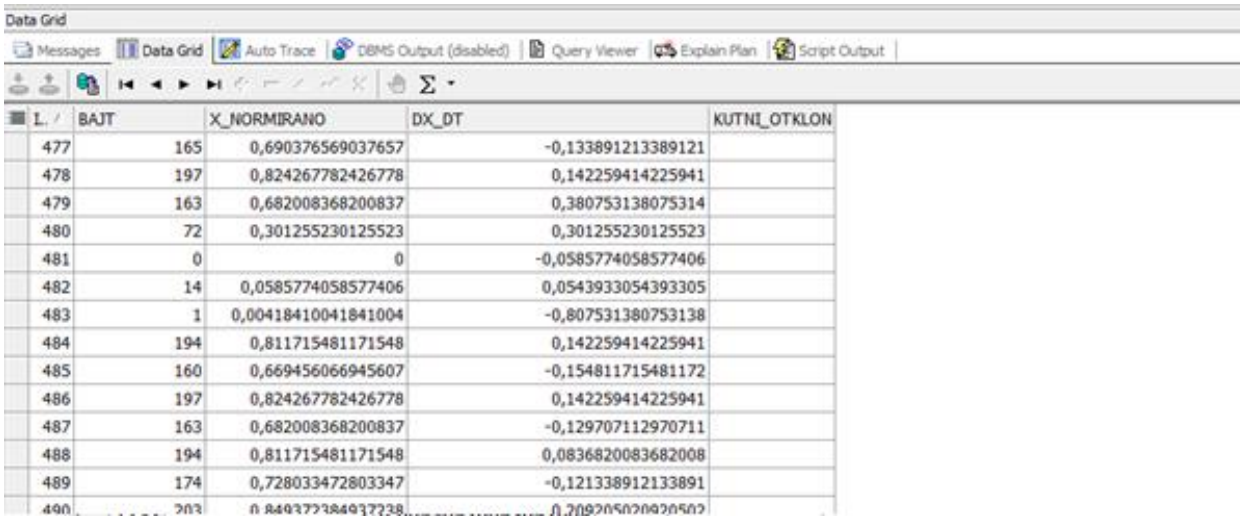

L.	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON
477	165	0,690376569037657	-0,133891213389121	
478	197	0,824267782426778	0,142259414225941	
479	163	0,682008368200837	0,380753138075314	
480	72	0,301255230125523	0,301255230125523	
481	0	0	-0,0585774058577406	
482	14	0,0585774058577406	0,0543933054393305	
483	1	0,00418410041841004	-0,807531380753138	
484	194	0,811715481171548	0,142259414225941	
485	160	0,669456066945607	-0,154811715481172	
486	197	0,824267782426778	0,142259414225941	
487	163	0,682008368200837	-0,129707112970711	
488	194	0,811715481171548	0,0836820083682008	
489	174	0,728033472803347	-0,121338912133891	
490	203	0,849372384937238	0,209205020920502	

Slika 4.4 Izračun kutnog otklona u bazi

Rezultat predhodnog računanja je premapiramn u REF notaciju, koja je bit samog modela, prema definiranoj tablici vrijednosti*.

dx / dt	REF oznaka
= 0	E
>0	R
<0	F

Slika 4.5 Oznake kutnog otklona

REF dx / dt	*REF oznaka*	*Koeficijent kutnog otklona dx / dt*	*Razred temeljem koeficijenta kutnog otklona (crisp)*
= 0	E	0	Jednako
>0	R	0-0.2	Slab rast
		0.2-0.6	Srednji rast
		0.6-1	Oštar rast
<0	F	0-0.2	Slab pad
		0.2-0.6	Srednji pad
		0.6-1	Oštar pad

Slika 4.6 Vrijednosti raspona unutar određenog kutnog otklona

*vrijednosti su početno preuzete iz doktorskog rada profesora Klepca, a problematikom vrijednost je obrađena dodatno kasnije u radu.

```
begin
for rst in(select id,DX_DT from refii)
loop
update refii set KUTNI_OTKLON =
case when rst.DX_DT=0 then 'Jednako'
when rst.DX_DT>0 and rst.DX_DT<0.2  then 'Slab rast'
when rst.DX_DT>0.2 and rst.DX_DT<0.6  then 'Srednji  rast'
when rst.DX_DT>0.6 and rst.DX_DT<1  then 'Oštar rast'
when rst.DX_DT<0 and rst.DX_DT>-0.2  then 'Slab pad'
when rst.DX_DT<-0.2 and rst.DX_DT>-0.6  then 'Srednji  pad'
when rst.DX_DT<-0.6 and rst.DX_DT>-1  then 'Oštar pad'
end
where id = rst.id;
commit;
end loop;
end;
```

Kod 4.6 Izračun kutnog otklona u REFII notaciji

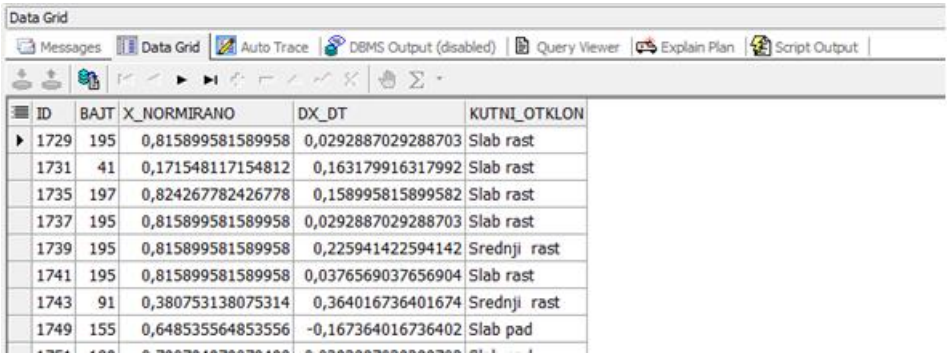
Data Grid

Messages | Data Grid | Auto Trace | DBMS Output (disabled) | Query Viewer | Explain Plan | Script Output

	ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON
▶	1729	195	0,815899581589958	0,0292887029288703	Slab rast
	1731	41	0,171548117154812	0,163179916317992	Slab rast
	1735	197	0,824267782426778	0,158995815899582	Slab rast
	1737	195	0,815899581589958	0,0292887029288703	Slab rast
	1739	195	0,815899581589958	0,225941422594142	Srednji rast
	1741	195	0,815899581589958	0,0376569037656904	Slab rast
	1743	91	0,380753138075314	0,364016736401674	Srednji rast
	1749	155	0,648535564853556	-0,167364016736402	Slab pad

Slika 4.7 Konkretne vrijednosti kutnog otklona

Slični koraci su napravljeni kod računanja kutnog otklona i njegovog mapiranja u REF notaciju i za površinu ispod krivulje.

Najprije je izračunata nenormirana površinu prema formuli :

$$p = \frac{(x_n * \Delta t) + (x_{n+1} * \Delta t)}{2} \tag{3}$$

```
declare
znakovi number;
i NUMBER DEFAULT 1;
begin
select max(id)  into znakovi from refii;
for i in 1..znakovi
loop
update refii set POVRSINA_NENORMIRANO = (select ((((select
BAJT  from refii where id = i)*16)+((select BAJT from refii
where id = i+1)*16))/2) from dual) where id = i;
commit;
end loop;
end;
```

Kod 4.7 Izračun površine

ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON	POVRSINA_NENORMIRANO	POVRSINA_NORMIRANO	POVRSINA_REF
2	203	0,849372384937238	0,209205020920502	Srednji rast	2848		
5	153	0,640167364016736	0,640167364016736	Oštar rast	1224		
9	153	0,640167364016736	-0,209205020920502	Srednji pad	2848		
11	153	0,640167364016736	0,640167364016736	Oštar rast	1224		
14	203	0,849372384937238	0,209205020920502	Srednji rast	2848		
18	0	0	-0,00836820083682...	Slab pad	16		
20	203	0,849372384937238	0,209205020920502	Srednji rast	2848		
22	195	0,815899581589958	0,0251046025104603	Slab rast	3072		

Slika 4.8 Prikaz izračuna površine

Zatim je isto normirano prema standardnoj formuli za normiranje koja je već korištena (formula 4.2).

```
begin
for rst in(
select id, POVRSINA_NENORMIRANO,(POVRSINA_NENORMIRANO -
(select min(POVRSINA_NENORMIRANO) from refii))/
((select max(POVRSINA_NENORMIRANO) from refii)-
(select min(POVRSINA_NENORMIRANO) from refii)) x_normirano_
from refii)
loop
update refii set POVRSINA_NORMIRANO = rst.x_normirano_ where
id = rst.id;
end loop;
end;
```

Kod 4.8 Normizacija površine

ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON	POVRSINA_NENORMIRANO	POVRSINA_NORMIRANO	POVRSINA_REF
1731	41	0,171548117154812	0,163179916317992	Slab rast	344	0,1	
1735	197	0,824267782426778	0,158995815899582	Slab rast	2848	0,827906976744186	
1737	195	0,815899581589958	0,0292887029288703	Slab rast	3064	0,890697674418605	
1739	195	0,815899581589958	0,225941422594142	Srednji rast	2688	0,781395348837209	
1743	91	0,380753138075314	0,364016736401674	Srednji rast	760	0,22093023255814	
1749	155	0,648535564853556	-0,167364016736402	Slab pad	2800	0,813953488372093	
1753	190	0,794979079497908	0,794979079497908	Oštar rast	1520	0,441860465116279	
1756	130	0,543933054393305	0,502092050209205	Srednji rast	1120	0,325581395348837	
1758	195	0,815899581589958	0,163179916317992	Slab rast	2808	0,816279069767442	
1764	195	0,815899581589958	0,0376569037656904	Slab rast	3048	0,886046511627907	
1765	186	0,778242677824268	-0,0460251046025105	Slab pad	3064	0,890697674418605	
1766	197	0,824267782426778	0,0502092050209205	Slab rast	3056	0,888372093023256	
1770	57	0,238493723849372	0,217573221757322	Srednji rast	496	0,144186046511628	
1771	5	0,0209205020920502	-0,0627615062761506	Slab pad	200	0,0581395348837209	

Slika 4.9 Normirana vrijednost površine

Na kraju je površina pretvorena u REFII notaciju, prema istim parametrima kao i kod kutnog otklona (slike 4.5 i 4.6)

```
begin
for rst in(select id,POVRSINA_NORMIRANO from refii)
loop
update refii set POVRSINA_REF =
case when rst.POVRSINA_NORMIRANO=0 then 'Jednako'
when rst.POVRSINA_NORMIRANO>0 and rst.POVRSINA_NORMIRANO<0.3
then 'Mala'
when rst.POVRSINA_NORMIRANO>0.3 and
rst.POVRSINA_NORMIRANO<0.6  then 'Srednja'
when rst.POVRSINA_NORMIRANO>0.6 and rst.POVRSINA_NORMIRANO<1
then 'Velika'
when rst.POVRSINA_NORMIRANO<0 and rst.POVRSINA_NORMIRANO>-0.2
then 'Mala'
when rst.POVRSINA_NORMIRANO<-0.2 and rst.POVRSINA_NORMIRANO>-
0.6  then 'Srednja'
when rst.POVRSINA_NORMIRANO<-0.6 and rst.POVRSINA_NORMIRANO>-
1  then 'Velika'
end
where id = rst.id;
commit;
end loop;
end;
```

Kod 4.9 Obračun površine prema REFII modelu

ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON	POVRSINA_NENORMIRANO	POVRSINA_NORMIRANO	POVRSINA_REF
1731	41	0,171548117154812	0,163179916317992	Slab rast	344	0,1	Mala
1735	197	0,824267782426778	0,158995815899582	Slab rast	2848	0,827906976744186	Velika
1737	195	0,815899581589958	0,0292887029288703	Slab rast	3064	0,890697674418605	Velika
1739	195	0,815899581589958	0,225941422594142	Srednji rast	2688	0,781395348837209	Velika
1743	91	0,380753138075314	0,364016736401674	Srednji rast	760	0,22093023255814	Mala
1749	155	0,648535564853556	-0,167364016736402	Slab pad	2800	0,813953488372093	Velika
1753	190	0,794979079497908	0,794979079497908	Oštar rast	1520	0,441860465116279	Srednja
1756	130	0,543933054393305	0,502092050209205	Srednji rast	1120	0,325581395348837	Srednja
1758	195	0,815899581589958	0,163179916317992	Slab rast	2808	0,816279069767442	Velika
1764	195	0,815899581589958	0,0376569037656904	Slab rast	3048	0,886046511627907	Velika
1765	186	0,778242677824268	-0,0460251046025105	Slab pad	3064	0,890697674418605	Velika
1770	57	0,238493723849372	0,217573221757322	Srednji rast	496	0,144186046511628	Mala
1771	5	0,0209205020920502	-0,0627615062761506	Slab pad	200	0,0581395348837209	Mala
1772	20	0,0836820083682008	-0,732217573221757	Oštar pad	1720	0,5	Srednja

Slika 4.10 Prikaz izračuna površine prema REFII notaciji

Novi izazov koji je primijećen je slijedeći - kad se podaci zapisuju veličina datoteke je preko 60 MB i to za otprilike 3 minute zvučnog zapisa. Dodatni izazov je i unos u tablicu za takav jedan zapis, te se pokušalo zapisati s odmakom u zapisivanju na 10 milisekundi, 50 milisekundi i 100 milisekundi. Primjenom takvog pristupa nad svakim od setova podataka pokušalo se utvrditi dolazi li do promjene podataka i promijene konstrukcije podataka i na koji način. Pošto je riječ o vremenski malim pomacima pretpostavka je da isti neće utjecati na izvlačenje predloška audio signala, što je potrebno provjeriti i dokazati.

Zato su napravljeni zapisi sa prekidom (delay) od 10 milisekundi, sa prekidom od 50 milisekundi i sa prekidom od 100 milisekundi.

Za sve tri datoteke, to jest za sva 3 seta podataka je odrađena priprema podataka prema koracima navedenim iznad.

Kako bi dobili potencijalno upotrebljiv predložak ostaje provjeriti količinu pojavnosti određenih vrijednosti.

Stoga je pregledana prva najčešće prisutnu pojavnost :

```
select count(*) kutni_otklon, kutni_otklon ko_opis  from
refii
group by kutni_otklon
order by kutni_otklon desc
```

Kod 4.10 Upit za najčešću pojavnost

KUTNI_OTKLON	KO_OPIS
1753	Slab rast
1560	Srednji rast
1203	Slab pad
868	Srednji pad
779	Oštar pad
519	Oštar rast
11	Jednako

Tablica 4.3: Broj pojedinih pojavnosti prema kutnom otklonu

Kao najveća vrijednost koja se pojavljuje je Slabi rast, nakon Slabog rasta slijedi odmah po učestalosti (nadovezuje se na njega) Slabi pad:

```
select count(*) kutni_otklon, kutni_otklon ko_opis  from
refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast')
group by kutni_otklon
order by kutni_otklon desc
```

Kod 4.11 Upit za najčešću pojavnost druge razine

KUTNI_OTKLON	KO_OPIS
741	Slab pad
423	Oštar rast
334	Srednji rast
136	Srednji pad
95	Oštar pad
19	Slab rast
4	Jednako

Tablica 4.4: Broj pojedinih pojavnosti prema kutnom otklonu, druga razina pojavnosti

Te slijedi opet Slabi rast:

```
select count(*) kutni_otklon, kutni_otklon ko_opis  from
refii
where id in
(select id+1  from refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast'))
group by kutni_otklon
order by kutni_otklon desc
```

Kod 4.12 Upit za najčešću pojavnost treće razine

KUTNI_OTKLON	KO_OPIS
668	Slab rast
423	Srednji rast
317	Oštar pad
263	Srednji pad
78	Slab pad
3	Jednako

Tablica 4.5: Broj pojedinih pojavnosti prema kutnom otklonu, treća razina pojavnosti

Dobiveno je da je najčešći uzorak zapisa u REF notaciji u varijanti **Slabi rast - Slabi pad – Slabi rast**.

Kada se doda površina dobiva se da REF vrijednost **Slabi rast** prati u 1521 slučaju Velika površina :

```
select count(*)  broj, i.kutni_otklon, I.POVRSINA_REF  from
refii i
where i.kutni_otklon = 'Slab rast'
and i.povrsina_ref = 'Velika'
group by i.kutni_otklon, POVRSINA_REF
union
select count(*) broj, i.kutni_otklon, I.POVRSINA_REF  from
refii i
where i.kutni_otklon = 'Slab rast'
```

```
and i.povrsina_ref = 'Mala'
group by i.kutni_otklon, POVRSINA_REF
```

Kod 4.13 Upit za pojavnost površine za prvu razinu pojavnosti kutnog otklona

BROJ	KUTNI_OTKLON	POVRSINA_REF
226	Slab rast	Mala
1521	Slab rast	Velika

Tablica 4.6: Broj pojavnosti vrijednosti površine za prvu stavku kombinacije pojavnosti kutnog otklona

Nadalje pristupljeno je izračunu i za drugu stavku u varijanti **Slabi rast - Slabi pad – Slabi rast.**

Te je dobiveno: **Slabi pad -Velika**

```
select count(*) broj, kutni_otklon ko_opis, POVRSINA_REF
from refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast')
and povrsina_ref = 'Velika'
group by kutni_otklon, POVRSINA_REF
union
select count(*) broj, kutni_otklon ko_opis, POVRSINA_REF
from refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast')
and povrsina_ref = 'Mala'
group by kutni_otklon, POVRSINA_REF
```

Kod 4.14 Upit za pojavnost površine za drugu razinu pojavnosti kutnog otklona

BROJ	KO_OPIS	POVRSINA_REF

684	Slab pad	Velika
57	Slab pad	Mala

Tablica 4.7: Broj pojavnosti vrijednosti površine za drugu stavku kombinacije pojavnosti kutnog otklona

Zaključno je napravljeno i za treću stavku:

```
select count(*)  broj, kutni_otklon, POVRSINA_REF  from refii
where id in
(select id+1  from refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast'))
and povrsina_ref = 'Velika'
group by kutni_otklon,POVRSINA_REF
union
select count(*)  broj, kutni_otklon, POVRSINA_REF   from
refii
where id in
(select id+1  from refii
where id in
(select i.id +1 from refii i
where kutni_otklon = 'Slab rast'))
and povrsina_ref = 'Mala'
group by kutni_otklon,POVRSINA_REF
```

Kod 4.15 Upit za pojavnost površine za treću razinu pojavnosti kutnog otklona

BROJ	**KUTNI_OTKLON**	**POVRSINA_REF**
580	Slab rast	Velika
88	Slab rast	Mala

Tablica 4.1 Broj pojavnosti vrijednosti površine za drugu stavku kombinacije pojavnosti kutnog otklona

Čime je dobiven zapis prvog uzorka u varijanti:

Kutni otklon	**Slabi rast**	**Slabi pad**	**Slabi rast**

Površina	**Velika**	**Velika**	**Velika**

Tablica 4.8: Prikaz kompletne vrijednosti uzorka

Definiran je navedeni događaj kao prvi uzorak prema kutnom otklonu u obliku koji je izračunat i zapisan u tablicu.

Ažurirani su svi root elementi za taj tip uzorka.

U dotičnom primjeru ih je 534.

	ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKL	POVRS	DOGADJAJ
2	80	194	0,811715481	0,083682008	Slab rast	2944	Slabi rast - Slabi pad - Slabi rast
3	89	195	0,815899582	0,037656904	Slab rast	3048	Slabi rast - Slabi pad - Slabi rast
4	91	195	0,815899582	0,108786611	Slab rast	2912	Slabi rast - Slabi pad - Slabi rast
5	117	195	0,815899582	0,037656904	Slab rast	3048	Slabi rast - Slabi pad - Slabi rast
6	123	195	0,815899582	0,029288703	Slab rast	3064	Slabi rast - Slabi pad - Slabi rast
7	188	195	0,815899582	0,029288703	Slab rast	3064	Slabi rast - Slabi pad - Slabi rast
8	190	194	0,811715481	0,09623431	Slab rast	2920	Slabi rast - Slabi pad - Slabi rast

Slika 4.11 Prikaz unosa događaja za korijenski element uzorka

```
update refii set DOGADJAJ = 'Slabi rast - Slabi pad - Slabi
rast' where id in
(select id from  refii i1 where kutni_otklon = 'Slab rast'
and exists(select 1 from  refii i2 where kutni_otklon = 'Slab
pad' and i2.id = i1.id+1)
and exists(select 1 from  refii i3 where kutni_otklon = 'Slab
rast' and i3.id = i1.id+2))
```

Kod 4.16 Upis događaja

Dodatno je proširena tablica sa vrstom događaja i to samo kod površine i u kombinaciji površine i kutnog otklona. Dodano je odmah za 3 najčešće varijante površine i kutnih otklona.

ID	BAJT	X_NORMIRANO	DX_DT	KUTNI_OTKLON	POVRSINA_NENORMIRANO	POVRSINA_NORMIRANO	POVRSINA_REF	DOGADJAJ1_KO	DOGADJAJ2_KO	DOGADJAJ3_KO	DOGADJAJ1_PO	DOGADJAJ2_PO	DOGADJAJ3_PO

Slika 4.12 Prikaz tablice sa dodanim poljima za 3 najčešća događaja

Sve je napravljeno za 3 vrste uzoraka, sa prekidom od 10,50, 100 milisekundi.

Dodatno napravljena je meta tablica:

ID	TABLICA	NAZIV	UZORAK1	UZORAK2	UZORAK3	SAMPLE_RATE	MILISEC_UPIS
1	REFII_DEMO_50	Pjesma1	Slabi rast - Mala, Slabi pad - Mala, Slabi pad - Mala			16	50

Slika 4.13 Meta tablica za svaki pojedini uzorak

Dobiveni su odsječci (na manjem setu podataka, jedna točka u plusu i zatim dva pada u minus. Ovdje se gleda samo kutni otklon.

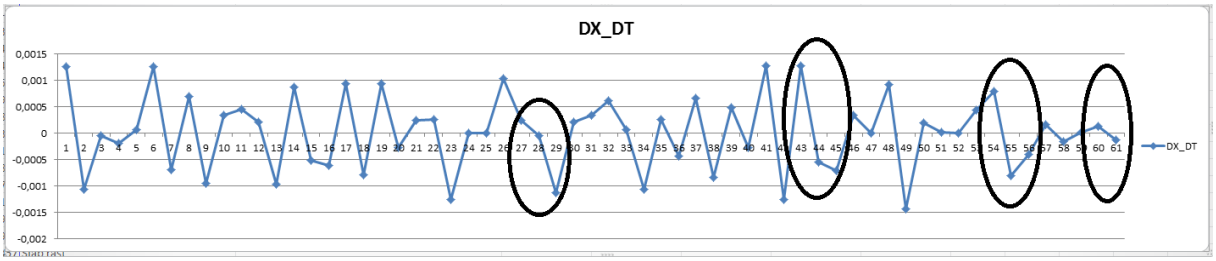

Slika 4.14 Slika grafičkog prikaza uzorka

Dobiveni su konačni podatci za varijante (50, 100 i 1000 milisekundi razmaka u zapisu):

	50		100		1000	
	Broj uzoraka	REFII	Broj uzoraka	REFII	Broj uzoraka	REFII
Prvi	30172	Slab pad	16370	Slab rast	1135	Slab pad

prolaz	29981	Slab rast	16084	Slab pad	1120	Slab rast
Drugi prolaz	8401	Slab rast	5141	Slab pad	321	Slab rast
	5641	Oštar rast	3152	Slab rast	214	Slab pad
Treći prolaz	6177	Slab pad	3444	Slab rast	232	Slab rast
	6177	Slab rast	3316	Slab pad	232	Slab pad

Tablica 4.9

Problematika je odmah vidljiva. Broj najfrekventnijih uzoraka je vrlo sličan i varira u REFII notaciji, iako su vrijednost vrlo blizu. Zbog toga je odlučeno da se ne koristiti apsolutne vrijednosti raspona unutar određenog kutnog otklona, već apsolutne, na način da nakon odabira korijenskog elementa isti postaje referentna nulta točka za izračun nove vrijednosti kutnog otklona.

Primjer:

Ako je prva vrijednost -0.6 što odgovara srednjem padu u REFII notaciji, onda slijedeća vrijednost koja je -0.2 nije slabi pad, već ako joj je nulta točka -0.6 je to srednji rast od 0.4 u apsolutnom iznosu.

Prema tome izračun za prvu najčešću pojavnost ostaje isti (kao u primjeru koda 4.10) dok REFII notaciju za drugu i treću pojavnost mijenja u izračunu na slijedeći način.

Ako se za konkretan primjer iz tablice vraća u prvom pregledu pojavnosti 16370 puta pojavnost stavke „Slab rast“. Sve vrijednosti DX_DT iz tablice za stavku „Slab rast“ upisuju se u novu tablicu, gdje će se računati referentne vrijednosti. Osim toga pokušati će se ne vezati površinu uz konkretnu pojavnost, već zbrojiti površine bez normiranja, te analizirati te podatke.

Nakon što je izračunata prvu pojavnost (kao u primjeru koda 4.10).

Ista je upisana u tablicu za novi izračun.

Pošto je poznata prva najveća pojavnost Slab rast, upisani su ti podatci:

```
insert into REFII_DEMO_100_NOVO  (prvi_id,
prvi_dx_dt,prvi_kutni_otklon,prvi_povrsina, prvi_refii)
select id prvi_id, dx_dt prvi_dx_dt,kutni_otklon
prvi_kutni_otklon, povrsina_nenormirano,kutni_otklon from
refii_DEMO_100
where kutni_otklon = 'Slab rast'
```

Kod 4.17 Upis u novu tablicu

Zatim su dodani podatci za drugu pojavnost, te su vezani uz ID prve:

```
begin
for rst in (
select id-1 root_id, id drugi_id, dx_dt
drugi_dx_dt,kutni_otklon
drugi_kutni_otklon,povrsina_nenormirano drugi_povrsina from
refii_DEMO_100
where id in
(select id +1 from refii_DEMO_100
where kutni_otklon = 'Slab rast')
and kutni_otklon = 'Slab pad'
)
loop
update REFII_DEMO_100_NOVO set drugi_id = rst.drugi_id,
drugi_dx_dt = rst.drugi_dx_dt, drugi_kutni_otklon=
rst.drugi_kutni_otklon, drugi_povrsina = rst.drugi_povrsina
where prvi_id = rst.root_id;
end loop;
end;
```

Kod 4.18 Upis u istu tablicu i slijedeće pojavnosti

Isto je napravljeno za treću pojavnost.

```
begin
for rst in (
select id -1 drugi_id, id treci_id, dx_dt
treci_dx_dt,kutni_otklon treci_kutni_otklon,
povrsina_nenormirano treci_povrsina from refii_DEMO_100
where id in
(select id +1 from refii_DEMO_100
```

```
where id in
(select id +1 from refii_DEMO_100
where kutni_otklon = 'Slab rast'))
and kutni_otklon = 'Slab rast'
)
loop
update REFII_DEMO_100_NOVO set treci_id = rst.treci_id,
treci_dx_dt = rst.treci_dx_dt, treci_kutni_otklon=
rst.treci_kutni_otklon, treci_povrsina = rst.treci_povrsina
where drugi_id = rst.drugi_id;
end loop;
end;
```

Kod 4.19 Upis u istu tablicu i treće pojavnosti

Čime je dobiven ovakav niz zapisa:

PRVI_ID	PRVI_DX_DT	PRVI_KUTNI_OTKLON	PRVI_POVRSINA	DRUGI_ID	DRUGI_DX_DT	DRUGI_KUTNI_OTKLON	DRUGI_POVRSINA	TRECI_ID	TRECI_DX_DT	TRECI_KUTNI_OTKLON	TRECI_POVRSINA	IZRACUN_POVRSINA
62666	0,129707113	Slab rast	2680	62667	-0,188284519	Slab pad	2792	62668	0,037656904	Slab rast	3080	
76687	0,108786611	Slab rast	2336	76688	-0,087866109	Slab pad	2296	76689	0,079497908	Slab rast	2312	
61482	0,075313808	Slab rast	3008	61483	-0,075313808	Slab pad	3008	61484	0,158995816	Slab rast	2848	
61498	0,037656904	Slab rast	3048	61499	-0,041841004	Slab pad	3056	61500	0,138075314	Slab rast	2872	
69204	0,041841004	Slab rast	2528	69205	-0,175732218	Slab pad	2784	69206	0,037656904	Slab rast	3048	
28	0,058577406	Slab rast	3024	29	-0,054393305	Slab pad	3016	30	0,0041841	Slab rast	3112	
1175	0,179916318	Slab rast	2776	1176	-0,188284519	Slab pad	2792	1177	0,008368201	Slab rast	3136	
2348	0,075313808	Slab rast	2976	2349	-0,071129707	Slab pad	2968	2350	0,167364017	Slab rast	2784	

Zbrojene su površine:

```
begin
for rst in (
select prvi_id, PRVI_POVRSINA,DRUGI_POVRSINA,TRECI_POVRSINA
from REFII_DEMO_100_NOVO where TRECI_ID is not null
)
loop
update REFII_DEMO_100_NOVO set IZRACUN_POVRSINA =
rst.PRVI_POVRSINA+ rst.DRUGI_POVRSINA+ rst.TRECI_POVRSINA
where prvi_id = rst.prvi_id;
end loop;
end;
```

Kod 4.20 Zbroj površina

Usporedbom podataka bilo je jasno da nisu dobivena nova saznanja. Naime vrijednosti se skoro uopće ne bi promijenile nakon što bi se kao referentnu točka koristio postojeći izračun bez obzira na apsolutni vrijednost.

Zatim je u obzir uzeta i distribuciji vrijednosti, te se došlo do slijedećeg zaključka.

Ukoliko se upotrijebi aritmetička sredinu jer su podaci normizirani, vrlo brzo se dođe do podataka da je prosječna razlika između apsolutnih vrijednosti prve i druge pojavnosti oko 0,042.

```
select count (*) from REFII_DEMO_100_NOVO where  DRUGI_DX_DT
is not null

select sum(abs(PRVI_DX_DT -DRUGI_DX_DT*(-1)))/5141 from
REFII_DEMO_100_NOVO where  DRUGI_DX_DT is not null
```

Kod 4.21 Provjera razlike u vrijednostima pojavnosti

Zbog toga je bilo potrebno izraditi novu tablicu vrijednosti raspona koeficijenta kutnog otklona u REF II notaciji.

REF dx / dt	REF oznaka	Koeficijent kutnog otklona dx / dt	Razred temeljem koeficijenta kutnog otklona (crisp)
=0	E	0	Jednako
>0	R	0 - 0,1	Jako slabi rast
		0,1 - 0,2	Slabi rast
		0,2 - 0,35	Slabi srednji rast
		0,35 - 0,5	Srednji rast
		0,5 - 0,75	Manje oštar rast
		0,75 - 1	Oštar rast
<0	F	0 - 0,1	Jako slabi pad
		0,1 - 0,2	Slabi pad
		0,2 - 0,35	Slabi srednji pad
		0,35 - 0,5	Srednji pad
		0,5 - 0,75	Manje oštar pad
		0,75 - 1	Oštar pad

Tablica 4.10 Nove REF vrijednosti

Te je cijeli postupak izračuna ponovljen s novim parametrima:

```
begin
for rst in(select PRVI_ID,PRVI_DX_DT  from
REFII_DEMO_50_NOVO)
loop
update REFII_DEMO_50_NOVO set PRVI_KUTNI_OTKLON =
case when rst.PRVI_DX_DT=0 then 'Jednako'
when rst.PRVI_DX_DT>0 and rst.PRVI_DX_DT<0.1  then 'Jako
slabi rast'
when rst.PRVI_DX_DT>0.1 and rst.PRVI_DX_DT<0.2  then 'Slab
rast'
when rst.PRVI_DX_DT>0.2 and rst.PRVI_DX_DT<0.35  then 'Slabi
srednji rast'
when rst.PRVI_DX_DT>0.35 and rst.PRVI_DX_DT<0.5  then
'Srednji  rast'
when rst.PRVI_DX_DT>0.5 and rst.PRVI_DX_DT<0.75  then 'Manje
oštar rast'
when rst.PRVI_DX_DT>0.75 and rst.PRVI_DX_DT<1  then 'Oštar
rast'
when rst.PRVI_DX_DT<0 and rst.PRVI_DX_DT>-0.1  then 'Jako
slabi pad'
when rst.PRVI_DX_DT<-0.1 and rst.PRVI_DX_DT>-0.2  then 'Slab
pad'
when rst.PRVI_DX_DT<-0.2 and rst.PRVI_DX_DT>-0.35  then
'Slabi srednji pad'
when rst.PRVI_DX_DT<-0.35 and rst.PRVI_DX_DT>-0.5  then
'Srednji  pad'
when rst.PRVI_DX_DT<-0.5 and rst.PRVI_DX_DT>-0.75  then
'Manje oštar pad'
when rst.PRVI_DX_DT<-0.75 and rst.PRVI_DX_DT>-1  then 'Oštar
pad'
end
where PRVI_ID = rst.PRVI_ID;
commit;
end loop;
end;
```

Kod 4.22 Obračun prema novim REF vrijednostima

Ponovnim obračunom dobivena je nova tablica raspodjele pojavnosti za četiri promatrana slučaja. Naime, dodan je još i obračun za 10 i 1000 ms.

	10		50		100		1000	
	Broj uzoraka	REFII	Broj uzoraka	REFII	Broj uzoraka	REFII	Broj uzoraka	REFII
Prvi	5497	Jako slabi pad	18140	Jako slabi pad	9822	Jako slabi rast	709	Jako slabi rast
prolaz	5496	Jako slabi rast	17885	Jako slabi rast	9651	Jako slabi pad	678	Jako slabi pad
Drugi prolaz	1011	Jako slabi rast	3286	Jako slabi rast	2136	Jako slabi pad	83	Jako slabi pad
	605	Slab rast	2058	Jako slabi pad	1276	Manje oštar rast	80	Jako slabi rast
Treći	209	Jako slabi pad	719	Jako slabi pad	448	Jako slabi rast	29	Jako slabi rast
prolaz	157	Slab rast	464	Manje oštar rast	285	Oštar rast	23	Oštar rast

Tablica 4.11 Skupni prikaz pojavnosti

Ono što se primjećuje je činjenica da kako počinje rasti razmak između zapisivanja točnost podataka se značajno gubi. Ali ono što se pokazalo dobrim je da u slučaju zapisa sa 10 ms gdje je upotrijebljeno 3 puta manje podataka nego kod zapisa od 50 ms, vrijednosti ostaju postojane.

Kako bi potpuno potvrdili navedeno napravljena je još i provjera sa čistim zapisom bez odmaka u zapisivanju.

Dobiveni rezultati nisu zadovoljili pretpostavku, tj. značajno su različiti rezultata koji su dobiveni bez pauza u zapisivanju nego s pauzama. Zaključak je da će se daljnja analitika raditi isključivo na „sirovim“ podacima. Te su svi navedeni koraci odrađeni i nad čistim zapisom dakle bez odmaka u zapisivanju.

	0	
	Broj uzoraka	REFII
Prvi prolaz	35968	Slabi srednji rast
	25918	Slab pad
Drugi prolaz	8690	Slab pad
	6988	Slabi srednji pad
Treći prolaz	1186	Slab rast
	1014	Jako slabi rast

Tablica 4.12 Skupni prikaz pojavnosti bez odmaka u zapisivanju

4.4. Stablo frekventnih uzoraka

Prije nego skupimo u bazu više podataka i počnemo testirati model potrebno je navedene podatke na neki način predstaviti i zapisati.

Ono što ćemo u ovom slučaju koristiti je stablo frekventnih uzoraka.

Stablo frekventnih uzoraka smo ustvari kreirali kroz našu provjeru pojavnosti prve, druge i treće razine. Ono što zapisujemo u njega je frekvencija pojavnosti određene oznake u REF notaciji, kako bi jednostavnije mogli napraviti konkretnu analizu i usporedbu.

Konkretno za sad imamo Korijen (root id) koji nam ujedno prikazuje prvu najfrekventniju pojavnost. Zatim on postaje korijen na osnovu kojeg tražimo prvu najfrekventniju pojavnost .

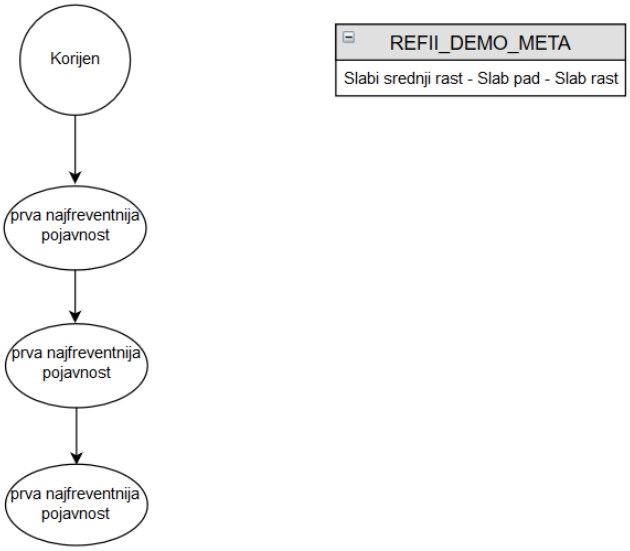

Slika 4.15 Osnovni prikaz stabla frekventnih uzoraka i uzorka u tablici

Što nam daje uzorak tipa: Slabi srednji rast - Slab pad - Slab rast, koji smo zapisali u tablicu meta podataka :

ID	TABLICA	NAZIV_PJESME	UZORAK1	SAMPLE_RATE	MILISEC_UPIS
1	REFII_DEMO_0	Ramones - swallow my pride	Slabi srednji rast - Slab pad - Slab rast	16	0

Tablica 4.13 Meta tablica

Izračunali smo odmah i uzorak za drugu najveću početnu pojavnost a to je u ovom slučaju bila Slab pad, iza čega slijedi Slab rast te Slab pad.

Pa tablica izgleda sad ovako:

ID	TABLICA	NAZIV	UZORAK1	UZORAK2
1	REFII_DEMO_0	Ramones - swallow my pride	Slabi srednji rast - Slab pad - Slab rast	Slab pad- Slab rast - Slab pad

Ako uzmemo u obzir da imamo 13 mogućih razreda temeljenih na koeficijentu kutnog otklona, onda imamo 2197 mogućih kombinacija uzorka. Ako tome dodamo i drugi uzorak onda je to 4 826 809 mogućnosti. Bez da smo dodali površinu. Ako uzmemo u obzir i treći uzorak taj broj jako puno raste. Pretpostavimo da bi sama činjenica da je riječ o muzici stvarala uzorke sličnog tipa, dodajmo našoj analizi i površinu.

Površinu također možemo definirati u REF notaciji, ali u ovom slučaju jednostavno ćemo zbrojiti površine da bi dobili oblik tipa:

PRVI_ID	PRVI_POVRSINA	DRUGI_ID	DRUGI_POVRSINA	TRECI_ID	TRECI_POVRSINA	IZRACUN_POVRSINA
1360	0,827906977	1361	0,806976744	1362	0,837209302	2,472093023
31790	0,827906977	31791	0,806976744	31792	0,83255814	2,46744186
1673	0,827906977	1674	0,809302326	1675	0,846511628	2,48372093
18781	0,827906977	18782	0,813953488	18783	0,830232558	2,472093023
18970	0,827906977	18971	0,813953488	18972	0,841860465	2,48372093

Tablica 4.14 Izračun površine

Još bi bilo dobro da izračunamo kolika je prosječna površina, odnosno median, što vrlo jednostavno možemo izračunati u Excelu, preko MEDIAN funkcije ili Data Analysis alata.

U našem konkretnom slučaju to ispada 2,460465116. Što na kraju upišemo u meta tablicu i dobijemo konačan podatak:

ID	TABLICA	NAZIV	UZORAK1	UZORAK2	SAMPLE_RATE	MILISEC_UPIS	POVRSINA
1	REFII_DEMO_0	Ramones - swallow my pride	Slabi srednji rast - Slab pad - Slab rast	Slab pad- Slab rast - Slab pad	16	0	2,460465116

Tablica 4.15 Konačni uzorak našeg primjena

Tako da s dodatnim podatkom o površini, to jest zbroju površine po pojedinom uzorku, možemo reći da imamo gotovo jedinstven zapis, odnosno uzorak za svaku pojedinu pjesmu. Ovo je samo hipoteza, te bi trebalo uložiti još puno truda kako bi se ista pokušala dokazati, te s pomoću ostalih analitičkih alata eventualno izvući zanimljivi podaci. Potencijalno osim u analitici zvučnih zapisa pjesama, ovakva metoda bi mogla imati upotrebljivost kod bilo kakvog zvučnog zapisa, a možda potencijalno i kod video zapisa.

Model je potrebno testirati na čim većem broju primjera te pokušati izvući vrijedne informacije o možda uzorku određenog žanra ili možda o jedinstvenom uzorku svake pojedine kompozicije.

Zaključak

Radom smo uspjeli pokazati na koji je način moguće primijeniti REFII model kod binarnog audio zapisa. Ta informacija doduše ne pokazuje ništa o tome da li bi se moglo tim načinom doći do ikakvih vrijednih informacija i dali primjena modela zaista može na toj razini dozvoliti značajnu analitiku, što bi još trebalo istražiti. Ukoliko ima mogućnosti da se dođe korištenjem modela do određenih vrijednih informacija, potencijal takve primjene može biti značajan. Kako u analizi zvučnih zapisa određenih kompozicija, tako i u analizi bilo kojeg zvučnog zapisa. Određena problematika kod ovog načina rada može se javiti zbog velike količine podataka za obradu, kako bi se dobio čim točniji model, za što su potrebni prije svega veliki kapaciteti baze podataka. Jer u radu je ustanovljeno da smanjenjem frekvencije upisa podataka, smanjujemo i točnost i kvalitetu pojavnosti, naročito onih koji su blizu granica prvih slijedećih pojavnosti.

Dakle početna pretpostavka da nad Fourierovom transformacijom možemo upotrijebiti REFFII model se pokazala pogrešnom, jer se gubi podatak o vremenskoj dimenziji. Također se pokazalo pogrešnim odmak u zapisivanju podataka jer se njime gubi kvaliteta podataka, no ono što smo uspjeli napraviti je upotreba REFII modela nad binarnim zvučnim zapisom i stvaranje konkretne informacije upotrebljive za dalju analizu, čime smo možda otvorili novo područje primjere REFII modela, čime smo uspjeli postaviti željenu hipotezu, opisanu u uvodu rada.

Prvenstvena ideja rada je praktičan rad i konkretna, upotrebljiva uputa kako nešto napraviti, što je nadam se napravljeno u duhu naziva fakulteta „primjenjivo računarstvo“. Namjera je nastaviti raditi na ovom i sličnom problemu u suradnji s profesorom, te se razvijati u tom smjeru.

Popis kratica

DHW - *data warehouse*

REFII - *Raise-Equal-Fall, druga verzija*

FFT - *fast Fourier transform*

Popis slika

Slika 2.1 Frekvencija 4

Slika 2.2 Amplituda signala 5

Slika 2.3 Analogno – digitalni pretvarač 5

Slika 2.4 Binarni zapisa audio signala 6

Slika 2.5 Digitalni zapis (lijevo) i njegov zapis u frekvencijskom opsegu (desno) 7

Slika 2.6 Opis konverzije digitalnog zapisa 8

Slika 4.1 Izgled datoteke binarnog zapisa 16

Slika 4.2 vrijednost audio zapisa u vremenskim razmacima 18

Slika 4.3 Prikaz normiranih vrijednosti u bazi 20

Slika 4.4 Izračun kutnog otklona u bazi 21

Slika 4.5 Oznake kutnog otklona 21

Slika 4.6 Vrijednosti raspona unutar određenog kutnog otklona 22

Slika 4.7 Konkretne vrijednosti kutnog otklona 23

Slika 4.8 Prikaz izračuna površine 24

Slika 4.9 Normirana vrijednost površine 24

Slika 4.10 Prikaz izračuna površine prema REFII notaciji 26

Slika 4.11 Prikaz unosa događaja za korijenski element uzorka 31

Slika 4.12 Prikaz tablice sa dodanim poljima za 3 najčešća događaja 32

Slika 4.13 Meta tablica za svaki pojedini uzorak 32

Slika 4.14 Slika grafičkog prikaza uzorka 32

Slika 4.15 Osnovni prikaz stabla frekventnih uzoraka i uzorka u tablici 40

Popis tablica

Tablica 3.1: Prikaz vrijednosti po sample-u 17

Tablica 3.2: Prikaz vrijednosti po sample-u u bazi 18

Tablica 3.3: Broj pojedinih pojavnosti prema kutnom otklonu 27

Tablica 3.4: Broj pojedinih pojavnosti prema kutnom otklonu, druga razina pojavnosti ... 27

Tablica 3.5: Broj pojedinih pojavnosti prema kutnom otklonu, treća razina pojavnosti.... 28

Tablica 3.6: Broj pojavnosti vrijednosti površine za prvu stavku kombinacije pojavnosti kutnog otklona 29

Tablica 3.7: Broj pojavnosti vrijednosti površine za drugu stavku kombinacije pojavnosti kutnog otklona 30

Tablica 3.8: Prikaz kompletne vrijednosti uzorka 31

Tablica 3.9 33

Tablica 3.10 Nove REF vrijednosti 36

Tablica 3.11 Skupni prikaz pojavnosti 38

Tablica 3.12 Skupni prikaz pojavnosti bez odmaka u zapisivanju 39

Tablica 3.13 Meta tablica 40

Tablica 3.14 Izračun površine 41

Tablica 3.15 Konačni uzorak našeg primjena 41

Popis kôdova

Kod 4.1 Definicija samle rate-a 14

Kod 4.2 TargetDataLine 15

Kod 4.3 Upis u datoteku 16

Kod 4.4 Izračun normizacije 20

Kod 4.5 Izračun kutnog otklona 21

Kod 4.6 Izračun kutnog otklona u REFII notaciji 22

Kod 4.7 Izračun površine 23

Kod 4.8 Normizacija površine 24

Kod 4.9 Obračun površine prema REFII modelu 25

Kod 4.10 Upit za najčešću pojavnost 26

Kod 4.11 Upit za najčešću pojavnost druge razine 27

Kod 4.12 Upit za najčešću pojavnost treće razine 28

Kod 4.13 Upit za pojavnost površine za prvu razinu pojavnosti kutnog otklona 29

Kod 4.14 Upit za pojavnost površine za drugu razinu pojavnosti kutnog otklona 29

Kod 4.15 Upit za pojavnost površine za treću razinu pojavnosti kutnog otklona 30

Kod 4.16 Upis događaja 31

Kod 4.17 Upis u novu tablicu 34

Kod 4.18 Upis u istu tablicu i slijedeće pojavnosti 34

Kod 4.19 Upis u istu tablicu i treće pojavnosti 35

Kod 4.20 Zbroj površina 35

Kod 4.21 Provjera razlike u vrijednostima pojavnosti 36

Kod 4.22 Obračun prema novim REF vrijednostima 37

Literatura

[1] ŽELJKO PANIAN, GORAN KLEPAC, Poslovna inteligencija. Zagreb: Masmedia, 2003.

[2] GORAN KLEPAC, Doktorska disertacija - Otkrivanje zakonitosti temeljem jedinstvenoga modela transformacije vremenske. Varaždin: Fakultet organizacije i informatike, 2005.

[3] LEO MRŠIĆ- Doktorska disertacija - Prijedlog izgradnje modela za podršku odlučivanju u trgovini korištenjem metode transformacije vremenske serije (refii) i bayesove logike. Zagreb: Filozofski fakultet, 2011.

[4] http://www.java2s.com/Tutorial/Java/0120__Development/CapturingAudiowithJavaSoundAPI.htm

[5] https://docs.oracle.com/javase/8/docs/technotes/guides/sound/programmer_guide/chapter5.html

[6] https://www.toptal.com/algorithms/shazam-it-music-processing-fingerprinting-and-recognition

[7] http://www.goranklepac.com/index.asp?j=HR&iz=1&sa=3&vi=1&hi=1

[8] http://www.enciklopedija.hr/Natuknica.aspx?ID=67594

[9] http://www.enciklopedija.hr/Natuknica.aspx?ID=20569

[10] http://www.enciklopedija.hr/Natuknica.aspx?ID=20308

„Pod punom odgovornošću pismeno potvrđujem da je ovo moj autorski rad čiji niti jedan dio nije nastao kopiranjem ili plagiranjem tuđeg sadržaja. Prilikom izrade rada koristio sam tuđe materijale navedene u popisu literature ali nisam kopirao niti jedan njihov dio, osim citata za koje sam naveo autora i izvor te ih jasno označio znakovima navodnika. U slučaju da se u bilo kojem trenutku dokaže suprotno, spreman sam snositi sve posljedice uključivo i poništenje javne isprave stečene dijelom i na temelju ovoga rada".

U Zagrebu, datum.

Prilog

Na zadnjim koricama s unutarnje strane nalazi se CD s kompletnim diplomskim radom u izvornom formatu i .pdf formatu sa svom popratnom dokumentacijom i programima, te s cijelom bazom koja je napravljena za potrebe izrade rada.