Prepoznavanje tempa pjesme iz glazbenog signala

Mostarac, Irena

Undergraduate thesis / Završni rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:964565

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I KOMUNIKACIJSKIH TEHNOLOGIJA

Sveučilišni studij

PREPOZNAVANJE TEMPA PJESME IZ GLAZBENOG SIGNALA

Završni rad

Irena Mostarac

Osijek, 2017.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju

Osijek, 19.09.2017.

Odboru za završne i diplomske ispite

Prijedlog ocjene završnog rada

Ime i prezime studenta:	Irena Mostarac
Studij, smjer:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	3945, 20.07.2014.
OIB studenta:	15352604612
Mentor:	Izv. prof. dr. sc. Irena Galić
Sumentor:	Hrvoje Leventić
Sumentor iz tvrtke:	
Naslov završnog rada:	Prepoznavanje tempa pjesme iz glazbenog signala
Znanstvena grana rada:	**Programsko inženjerstvo (zn. polje računarstvo)**
Predložena ocjena završnog rada:	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	19.09.2017.
Datum potvrde ocjene Odbora:	27.09.2017.

Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

IZJAVA O ORIGINALNOSTI RADA

Osijek, 25.09.2017.

Ime i prezime studenta:	Irena Mostarac
Studij:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	3945, 20.07.2014.
Ephorus podudaranje [%]:	1%

Ovom izjavom izjavljujem da je rad pod nazivom**: Prepoznavanje tempa pjesme iz glazbenog signala**

izrađen pod vodstvom mentora Izv. prof. dr. sc. Irena Galić

i sumentora Hrvoje Leventić

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

Sadržaj

1. UVOD 1
1.1. Zadatak završnog rada 1
2. OBRADA SIGANALA 2
2.1. Metoda otkucaja 2
2.2. Fourierova transformacija 3
2.3. Tolonenova i Karjalainenova metoda obrade signala 5
2.4. Scheirerova metoda obrade signala 7
3. REZULTATI 9
3.1. Rezultati mjerenja Scheirerovom metodom 9
3.2. Rezultati mjerenja metodom otkucaja 10
3.3. Usporedni rezultati između mjerenja Scheirerovom metodom i metodom otkucaja 11
4. ZAKLJUČAK 16
LITERATURA 18
SAŽETAK 20
ABSTRACT 20
POPIS I OPIS UPOTRIJEBLJENIH KRATICA 21
ŽIVOTOPIS 22
PRILOG – DETALJNI REZULTATI MJERENJA 23

1. UVOD

Tempo se određuje kako bi se dobila informacija o brzini otkucaja glazbenog signala. Kao jednostavna metoda se nameće da čovjek svojim slušanjem glazbenog signala, rukom otkuca brzinu izvođenja glazbenog djela. Najčešće je riječ o otkucavanju glazbenog signala u jednoj minuti, te se nakon toga pobroji količina otkucaja i dobije broj otkucaja u minuti.

Budući da ljudsko uho ima određeni spektar tlaka zvuka i frekvencija na kojim čuje, određivanje tempa otkucavanjem čovjeka nije najbolje rješenje za sve ljude. Pri tom procesu se događaju tri greške: zbog nedovoljno istaknutog sluha, nedovoljne mehaničke vještine čovjeka za otkucavanje te mehaničke sposobnosti uređaja na kojem se kuca.

Kako bi se izbjegle te tri pogreške kod svakodnevnog čovjeka, došlo se na ideju određivanja tempa računalnim putem. Glazbeni signal se pretvori u valni oblik, preko Fourierove transformacije se obradi signal te iz nje izvlači količina bita po minuti. Na taj način, jednako i glazbeno nadareni i glazbeno nenadareni ljudi, dobivaju rezultati za sve vrste glazbe, a posebno za one s istaknutijom količinom udaraca u glazbenoj pozadini. Izdvojeni otkucaji u pozadini dat će jasniji glazbeni signal koji program lako može prepoznati, samim time lakše i odrediti količinu otkucaja u minuti.

1.1. Zadatak završnog rada

Zadatak određivanja tempa iz glazbe je saznati koliko bita po minuti dođe iz glazbenog signala. Za određivanje se upotrebljava nekoliko metoda, nekoliko žanrova te se na osnovu usporednih rezultata određuje koja metoda je najprikladnija za koji žanr glazbe.

2. OBRADA SIGANALA

Valni oblik glazbenog signala je sastavljen od mnogobrojnih vrhova različitih visina i udaljenosti. [1] Mjerenjem udaljenosti tih vrhova je moguće dobiti tempo glazbenog signala. Pri čemu je prema (2-1) tempo obrnuto proporcionalan udaljenosti d između ta dva vrha. Kako se gleda tempo u jednoj minuti cijeli proces se množi sa 60.

$$BPM = \frac{1}{d} \cdot 60 \tag{2-1}$$

Za mjerenje tempa na taj način bi idealno bilo kada bi sve udaljenosti bile jednake, što je u praksi jako rijetko. Stoga se signal dijeli na nekoliko dijelova koji su približno monotoni.

Također ni svi dijelovi glazbenog signala nemaju jednaku količinu informacije o ritmu. Poznato je da je na nižim frekvencijama istaknutiji glazbeni tempo. Takav problem bi jednostavno mogao riješiti niskopropusni filtar, međutim problem bi se javio kod signala koji ne sadrže bas ili udaraljke, tj. kod nejasnog signala za niskopropusni filtar.

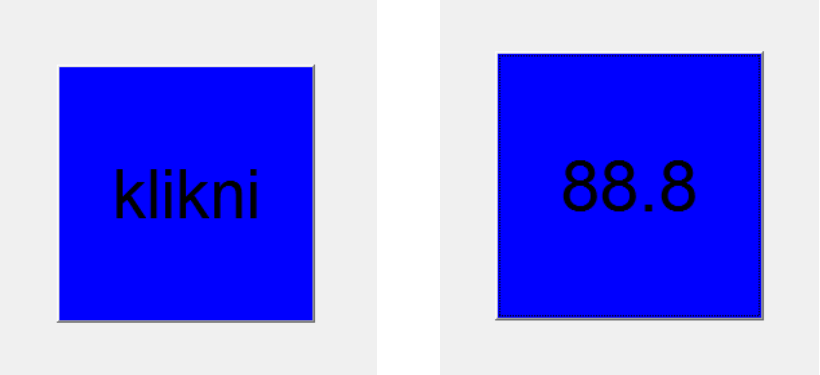
Postoji nekoliko metoda rješavanja tog problema, a sve, osim metode otkucaja se temelje na postavljanju niza filtara te obradi signala Fourierovom transformacijom i obrnutom Fourierovom transformacijom. Niz se sastoji od 2 pa na više filtara. Dok se kod metode otkucaja uopće ne koristi računalna obrada

2.1. Metoda otkucaja

Još pri samim početcima obrade glazbe od strane DJ-a nametalo se pitanje određivanja količine otkucaja u glazbenom signalu. Naime, DJ-evi su željeli ukomponirati dva glazbena signala u jedan i od toga dobiti neki novi, zabavniji zvuk. To nije bilo izvedivo za sve kombinacije glazbe jer je jako loše zvučalo. Ubrzo su shvatili važnost sličnosti tempa ukomponiranih glazbenih signala. Najjednostavnije je bilo na klasičan školski način odrediti tempo, dakle, kucanjem rukom.

Osoba bi pustila da se jedna te ista pjesma vrti u krug te bi na osnovi sluha otkucavala svaki glazbeni otkucaj. Na kraju bi se broj otkucaja podijelio na broj minuta te se dobio broj otkucaja u minuti(BPM) metodom otkucaja. Vrlo ubrzo je to određivanje postalo naporno i previše dugotrajno te de došlo na ideju da se na osnovu samo nekoliko prvih otkucaja odredi tempo, tako što bi se broj otkucaja podijelio s brojem otkucajnih sekundi, a nakon toga pomnožio sa 60(broj sekundi u minuti).

Takav način ubrzao je postupak određivanja s metodom otkucaja, ali davao i nešto netočnije rezultate, nego otkucavanje kroz cijeli glazbeni signal. To je i dalje davalo dovoljno precizan rezultat za tu svrhu jer je nepotrebna stopostotna podudarnost količine otkucaja, a i glazba nema na svim dijelovima jednaku količinu otkucaja u pozadini.[2]



Sl. 2.1. Prikaz brojača otkucaja, prije otkucavanja(lijevo) i poslije otkucavanja(desno) u Matlabu

2.2. Fourierova transformacija

Budući da je poznato kako se najlakše obrađuju sinusni i kosinusni signali pogodno je da su svi signali prikazani preko zbroja sinusa i kosinusa. Jean Baptiste Joseph Fourier je došao na ideju da sve periodične signale prikaže kao sumu sinusa i kosinusa. Ta suma se naziva Fourierov red.

Fourierov red vrijedi za sve periodične funkcije koje imaju period [-T/2, T/2]. Ako je funkcija neperiodična može se uzeti u obzir da joj je interval ponavljanja beskonačno te se tako svesti na periodičnu funkciju. Svođenjem i neperiodičnih funkcija na periodične zapravo se dobije rezultat kako se sve funkcije mogu rastaviti na Fourierov red.

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^{n} a_k \sin(kx + \Phi_k), \qquad n \geq 0 \tag{2-2}$$

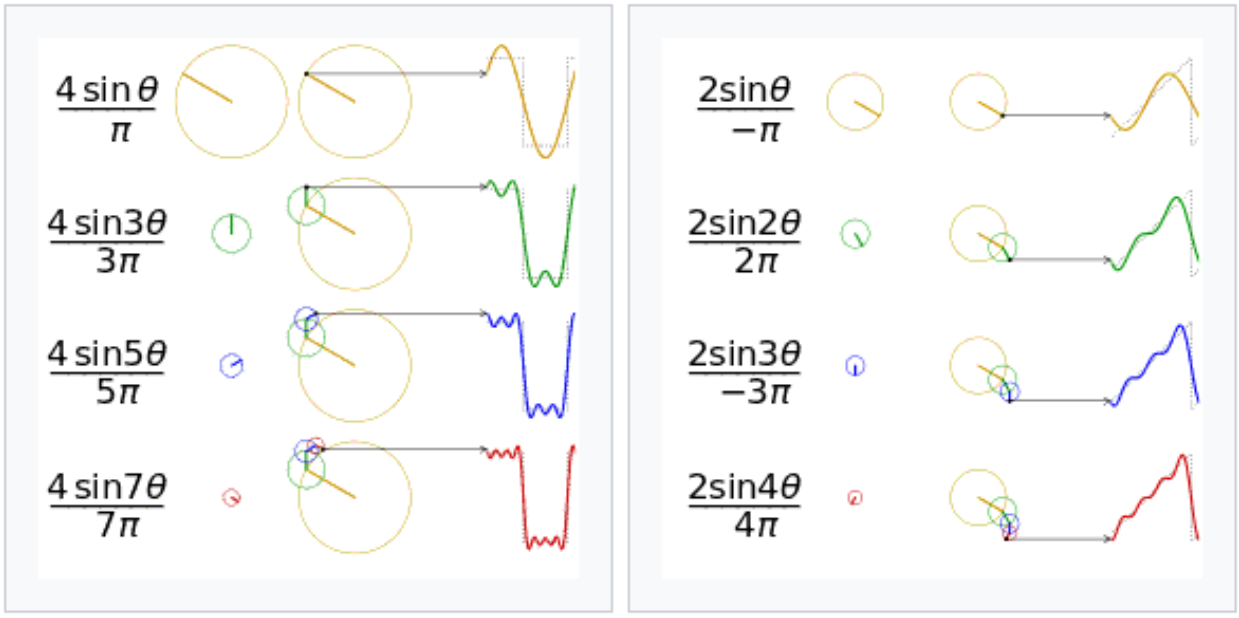
Pri čemu je a_k amplituda, a Φ_k faza sinus funkcije frekvencije k. $\frac{a_0}{2}$ predstavlja translaciju funkcije po y-osi, često se naziva DC komponentom.

Ako se primjeni adicijska formula za sinus funkciju formula za Fourierov red će se moći zapisati:

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^{n} (a_k \sin(kx)\, cos\Phi_k + a_k \cos(kx) sin\Phi_k). \tag{2-3}$$

Iz formule je vidljivo kako su $sin\Phi_k$ i $cos\Phi_k$ konstante te se mogu posmatrati kao jedna cjelina s koeficjentima a_k dobiva se konačan izraz za Fourierov red:[3]

$$f(x) = \frac{a_0}{2} + \sum_{k=1}^{n} (a_k \sin(kx) + b_k \cos(kx)) \ , \qquad n \geq 0. \tag{2-4}$$



Sl. 2.2. Usporedni prikaz Fourierovog reda pravokutne i trokutaste funkcije za 1., 2., 3. i 4. član Fourierovog reda pojedine funkcije. Izvor: [4]

Iz slike 2.2. je vidljivo kako uzimajući što veći broj harmonika u obzir, funkcija se vjerodostojnije prikazuje preko sume sinusa i kosinusa.

Koristeći Eulerovu formulu i uzimajući u obzir beskonačni interval Fourierov red možemo zapisati u obliku:

$$f(x) = \sum_{k=-\infty}^{\infty} \frac{1}{T} F\left(\frac{k}{T}\right) e^{\frac{2\pi k x i}{T}} \tag{2-5}$$

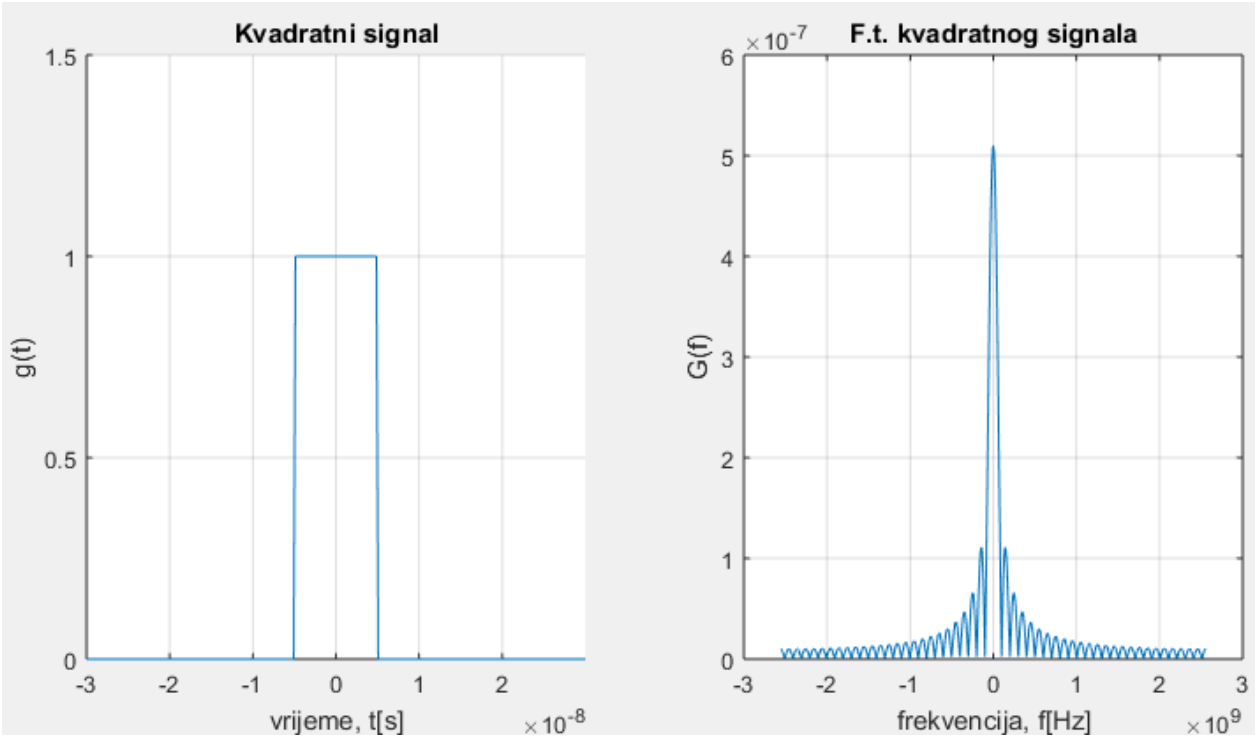
Kada se pusti varijabla $T \to \infty$, varijabla k / T prelazi iz diskretne varijable u kontinuiranu varijablu s te formula (2-5) postaje:

$$F(s) = \int_{-\infty}^{\infty} f(x) e^{-2\pi s x i} \, dx \tag{2-6}$$

Time se dobije Fourierova transformacija, dok obrat te funkcije glasi:

$$f(x) = \int_{-\infty}^{\infty} F(s)e^{2\pi sxi}\, ds \tag{2-7}$$

S Fourierovom transformacijom se može iz vremenske domene preći u frekvencijsku.[5]

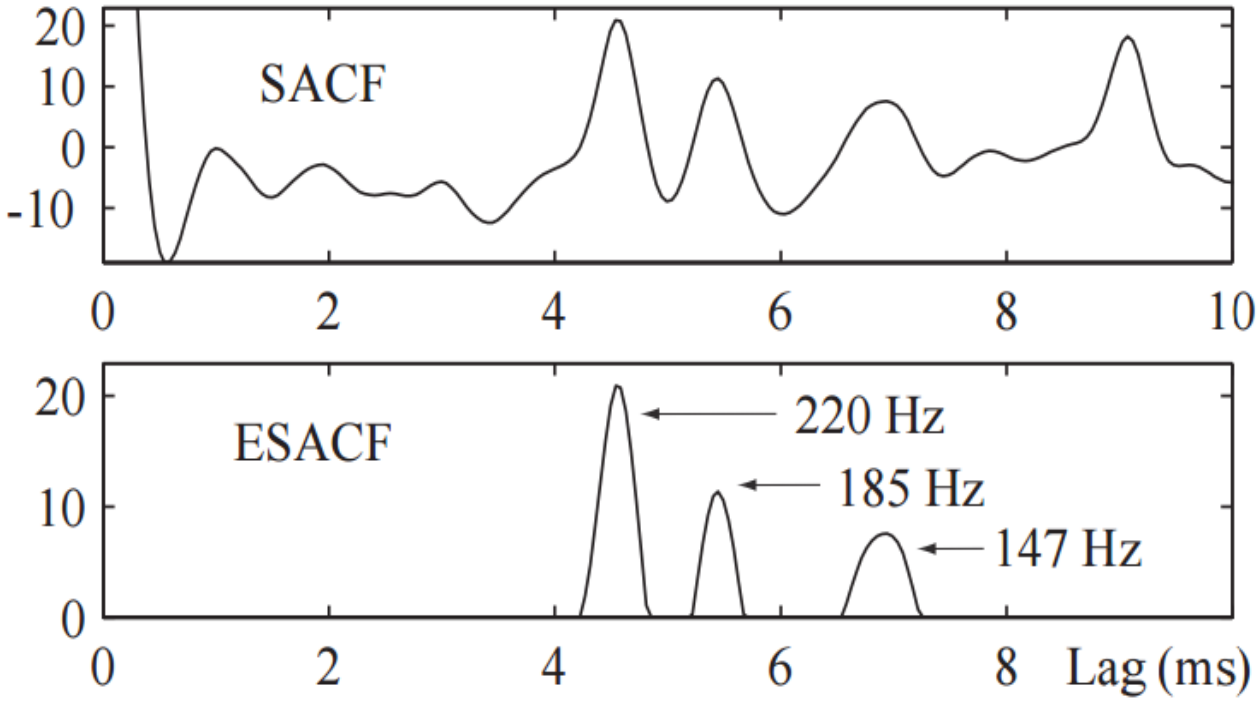


Sl. 2.3. Prikaz pravokutnog impulsa u vremenskoj(lijevo) i frekvencijskoj(desno) domeni

2.3. Tolonenova i Karjalainenova metoda obrade signala

Najjednostavniju računalnu metodu su razvili Tolonen i Karjalainen pri kojoj su signal podijelili na dva područja: od 20 kHz do 1 kHz i od 1 kHz do10 kHz. Signal se dakle dijeli na visokofrekvencijski i niskofrekvencijski. Zatim se Fourierovom transformacijom prebacuje signal u frekvencijsku domenu gdje se vrši kompresija signala. Takav signal se obrnutom Fourierovom transformacijom vraća u vremensku domenu. Svi dobiveni signali na kraju te autokorelacijske funkcije se zbrajaju.[6]

Dalje dolazi do problema identifikacije signala budući da osnovne frekvencije odgovaraju cjelobrojnom višekratniku osnovnog perioda. Poboljšanje je izvršeno odsijecanjem negativne periode, tako da se vremenska domena pomnoži s dva. Za rezultate se dobije signal s dosta manje izraženim drugim harmonicima. Daljnja poboljšanja su moguća s množenjem drugim faktorima kao što u 3 i 4 kako bi se riješili harmonika tog reda.

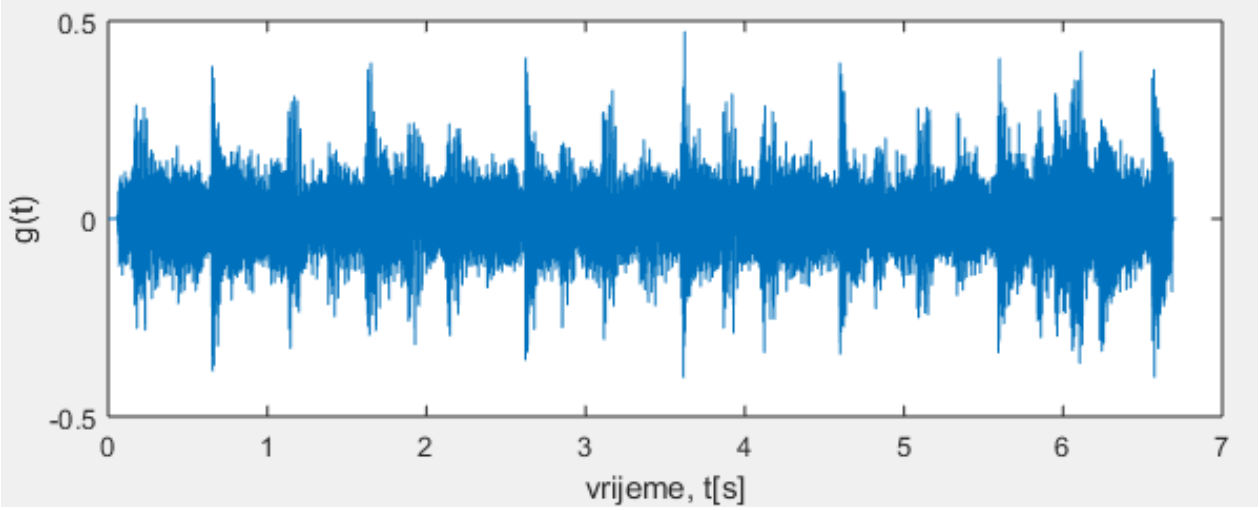


Sl. 2.4. Adicijska autokorelacijska funkcija (gore) i poboljšana adicijska autokorelacijska funkcija (dolje). Izvor:[5]

Poboljšanja su vidljiva na slici 2.4. na kojoj je odsijecanjem negativnih dijelova ostaju samo vrhovi koji nose bitne dijelove informacije. Tim postupkom se ubrzava cijeli proces određivanja količine otkucaja u minuti.

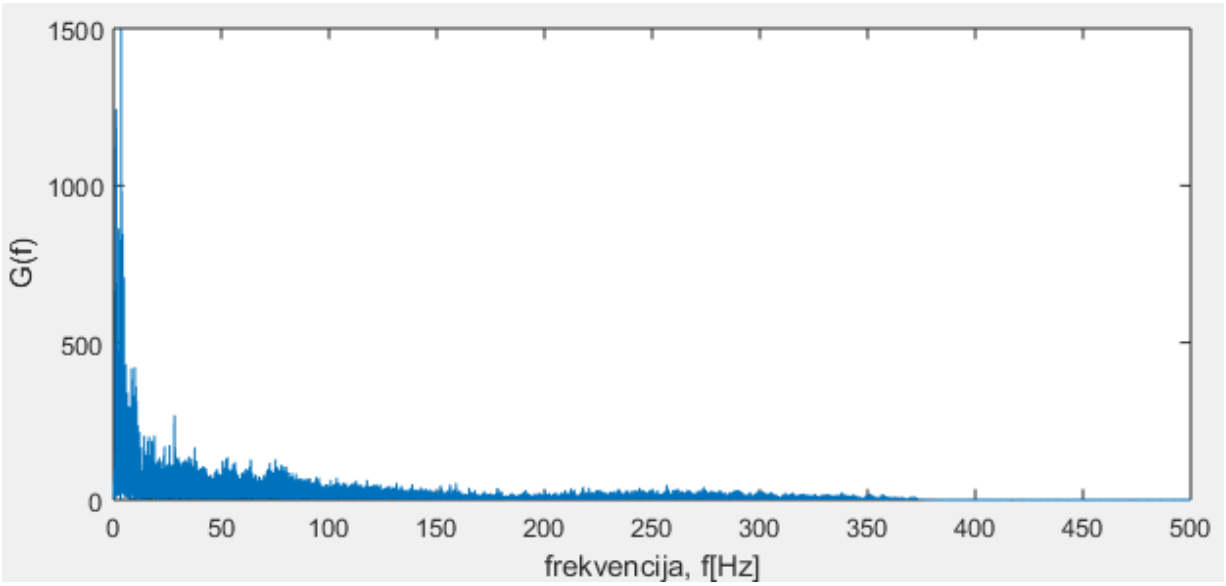
2.4. Scheirerova metoda obrade signala

Scheirer je ponudio poboljšano rješenje sa šest eliptičnih filtara koji se primjenjuju na glazbeni signal u valnom obliku (Sl.2.5.).



Sl. 2.5. Glazbeni signal na ulazu u filtre

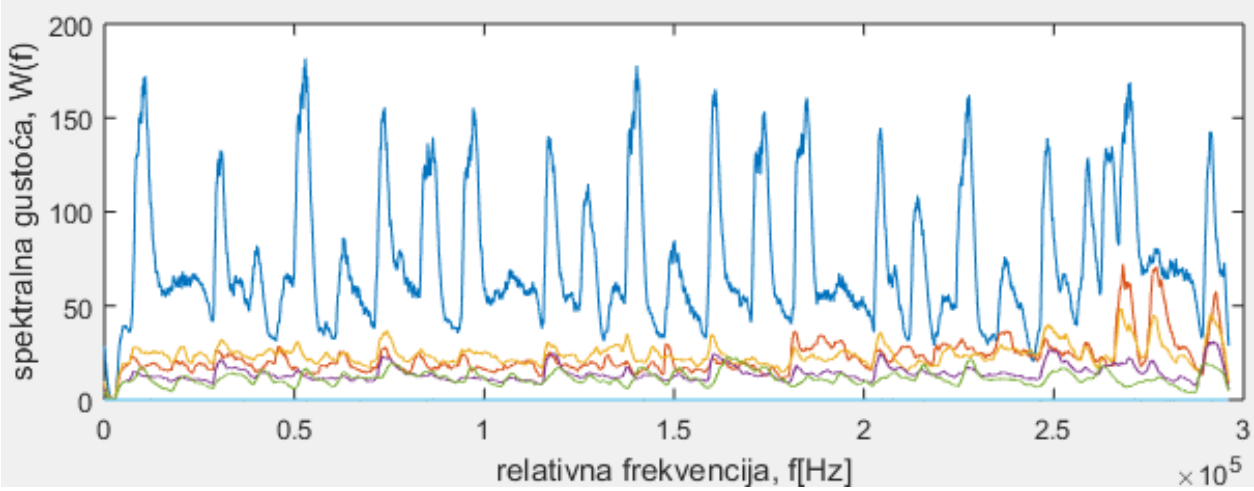
Najniži filtar je niskopropusni do 200 Hz, slijede 4 pojasnopropusna filtra 200 i 400 Hz, 400 i 800 Hz, 800 i 1600 Hz te 1600 i 3200 Hz. Nakon kojih ide visokopropusni filtar za 3200 Hz. Poslije primjene filtara dobiva se 6 glazbenih signala iz kojeg svakog pojedinačno se izvlači ovojnica zvučnog signala. Slika 2.6. je prikaz signala u jednom od filtera.[7]



Sl. 2.6. Glazbeni signal nakon primjene filtra

Nakon toga se signal propušta kroz Hannov prozor koji je opisan jednadžbom (2-8).

$$w(n) = 0.5\left(1 - cos\left(\frac{2\pi n}{N-1}\right)\right) \tag{2-8}$$



Sl. 2.7. Prolazak signala kroz Hannov prozor razdvojen po bojama za pojedini filter

Signal je nakon toga dobro definiran i pomoću autokorelacijske funkcije se jednostavno može odrediti razmak između vrhova ovojnice što će dati rezultate tempa glazbenog signala prema (2-1).[8, 9]

Kod ovakvih metoda se javlja problem određivanja pravog tempa. U Tolonenovoj i Karjalainenovoj metodi su tu bila dva filtra koja su dala za rezultat dva tempa, dok kod Scheirerove metode je bilo 6 filtera što daje još veće dvojbe pri pronalasku pravog tempa.

Za početak se iz razmatranja izbacuje svaki tempo koji je izvan granica od 40 do 220 bpm-a (bit per minute) jer je većina glazbenih zapisa u tom rasponu.

Kod prve metode je izvrsno ako oba filtra daju jednake rezultate, tada je to definitivno i konačan rezultat. Međutim, i kod druge metode se primjenjuje taj postupak, jer ako dva filtra daju jednak rezultat, velika je mogućnost da je to i zaista tempo glazbenog signala.

U slučaju da nema podudaranja za točniji izračun tempa se uzimaju rezultati na nižim frekvencijama jer su glazbeni signali obično bolje definirani na nižim frekvencijama.[10, 11]

3. REZULTATI

Mjerenje je izvršeno s dvije metode: Scheirerovom metodom (S.M.) i metodom otkucaja (M.O.). Svakom metodom je izmjerena količina bita u minuti nad 16 pjesma po žanru. Žanrova je također obrađeno 16 pri tome su uzeti najistaknutiji glazbeni žanrovi (glazba afričkog podrijetla, glazba azijskog podrijetla, blues, klasična glazba, country, dance/electronic, jazz, latino, pop, r&b, rap i rock) i nekoliko karakterističnih za balkansko područje (domaći pop, domaći rock, folk i izvorna glazba).

3.1. Rezultati mjerenja Scheirerovom metodom

Scheirerova metoda je obrađena u Matlab okruženju. Kako bi Matlab mogao izvršiti potrebne procese nad uzorcima pjesama, te u konačnici odrediti njihov BPM, sam glazbeni signal prije dolaska u program je morao biti obrađen. Obrada se vršila u dva koraka: izrezivanje glazbenog signala te izražavanja glazbenog mp3 signala u glazbeni valni oblik (.wav). Navedeni koraci su izvršeni u besplatnim verzijama online programa: Audio cutter[1] i TwistedWave[2]. Glazbeni signal se morao izrezati na manju duljinu od prosječne duljine pjesme. Matlab dosta lakše obrađuje signale do 7 sekundi. Glazbeni tempo je teoretski moguće odrediti iz signala duljine od samo 2 sekunde. Međutim, praktično se pokazalo da je puno bolji interval od 2.2 s. U namjeri da se nad istim signalom obradi i Scheirerova metoda i metoda otkucaja, uzeti su signali čije se duljine kreću od 6 do 7 sekundi, iz razloga jer je gotovo nemoguće metodom otkucaja odrediti tempo nad samo 2.2 s dugog signala. Računalnom obradom signala, bez obzira na količinu ponavljanja mjerenja je uvijek dobiven jednak rezultat za pojedini glazbeni signal, stoga ponavljanje mjerenja nikada nije bilo potrebno.

U tablici 3.1. je vidljivo koliki je prosječni broj BPM-a i koliki je iznos njegove srednje pogreške. Također je vidljiva i relativna pogreška koja govori da se srednja odstupanja kreću od 1,57% do 7,58% što nije preveliko odstupanje, štoviše u velikoj mjeri je prihvatljivo. Za sveukupnu relativnu pogrešku se može reći kako je odličan rezultat te da je mjerenje uspješno izvedeno.

[1] http://mp3cut.net/
[2] https://twistedwave.com/online/

Glazbeni žanr	Prosječan rezultat BPM za S.M.	Prosječna pogreška za S.M.	Relativna pogreška za S.M. [%]
Glazba afričkog podrijetla	110,81	6,95	6,27
Glazba azijskog podrijetla	104,94	7,95	7,58
Blues	144,44	6,87	4,76
Klasična glazba	192,44	3,03	1,57
Country	123,56	6,43	5,20
Dance/electronic	169,94	5,03	2,96
Domaći pop	111,75	5,89	5,27
Domaći rock	125,13	7,98	6,38
Folk	104,94	5,74	5,47
Izvorna glazba	186,06	4,12	2,21
Jazz	180,06	4,62	2,57
Latino	90,44	4,40	4,87
Pop	135,44	7,69	5,68
R&B	130,25	7,39	5,67
Rap	95,69	5,96	6,23
Rock	139,69	6,93	4,96
Ukupno	**134,10**	**6,06**	**4,85**

Tab. 3.1. Prosječni i relativni rezultati mjerenja za Scheirerovu metodu

3.2. Rezultati mjerenja metodom otkucaja

Metoda otkucaja izvršena je u online programu Beats Per Minute Calculator and Counter[3]. Mjerenje je vršeno tako što je u pozadini pušten glazbeni signal, a zatim otkucavan glazbeni tempo. Glazbeni signal je pušten da se vrti u krug te je tipkan svaki put sve dok se broj BPM-a nije ustalio. Ipak u slučajevima velikog rasipanja mjernih rezultata, mjerenje je ponavljano nekoliko puta.

Iz tablice 3.2. se može vidjeti prosječni broj otkucaja za pojedini žanr te koliko prosječno odstupa koji žanr od srednje svoje vrijednosti. Radi bolje uočljivosti odstupanja vidljiva je i relativna pogreška. Relativne pogreške se kreću od 1,55% do 4,83% što su jako male pogreške. Sveukupni rezultat od 3,40% označava odlično mjerenje metodom otkucaja.

[3] http://www.beatsperminuteonline.com/

Glazbeni žanr	Prosječan rezultat BPM za M.O.	Prosječna pogreška za M.O.	Relativna pogreška za M.O. [%]
Glazba afričkog podrijetla	126,19	4,84	3,84
Glazba azijskog podrijetla	103,00	4,97	4,83
Blues	95,06	3,63	3,82
Klasična glazba	188,19	2,92	1,55
Country	117,06	3,89	3,32
Dance/electronic	169,31	5,09	3,01
Domaći pop	110,75	2,50	2,26
Domaći rock	124,31	4,15	3,34
Folk	119,64	3,80	3,18
Izvorna glazba	118,44	3,49	2,95
Jazz	124,69	3,56	2,86
Latino	102,19	3,31	3,24
Pop	115,19	4,11	3,57
R&B	98,19	4,03	4,10
Rap	88,75	3,87	4,36
Rock	135,69	5,67	4,18
Ukupno	**121,04**	**3,99**	**3,40**

Tab. 3.2. Prosječni i relativni rezultati mjerenja za metodu otkucaja

3.3. Usporedni rezultati između mjerenja Scheirerovom metodom i metodom otkucaja

Podudarnost metoda za pojedini žanr je izražena kao relativna točnost R između broja BPM za određeni glazbeni signal. Relativna točnost je računata prema (3-1).

$$R\ [\%] = \left(1 - \frac{|BPM_{M.O.} - BPM_{S.M.}|}{BPM_{M.O.}}\right) \cdot 100 \qquad (3\text{-}1)$$

Pri čemu je $BPM_{M.O.}$ broj otkucaja u minuti metodom otkucaja, a $BPM_{S.M.}$ broj otkucaja u minuti Scheirerovom metodom.

Za obradu rezultata je kao točnija, teoretska vrijednost uzeta vrijednost metodom otkucaja iz razloga što Scheirerova metoda na više mjesta ima ogromna, vidna odstupanja. Na primjer kod jako sporih pjesama za rješenje je davala veliki broj otkucaja ili obratno.

Također, gledajući i relativne pogreške od prosječnih odstupanja za pojedinu metodu, metoda otkucaja je za sve žarove osim za dance/electronic dala precizniji rezultat, a i za taj žanr je razlika samo 0,02%.

Ukupna točnost za pojedini žanr izračunata je kao srednja vrijednost relativnih točnosti za pojedine glazbene signale pripadajućeg žanra.

$$A[\%] = \frac{\sum_{i=0}^{n} R_i}{n} \tag{3-2}$$

Pri čemu je R_i relativna točnost BPM za pojedinu pjesmu, a n broj obrađenih pjesama (u ovom slučaju 16).

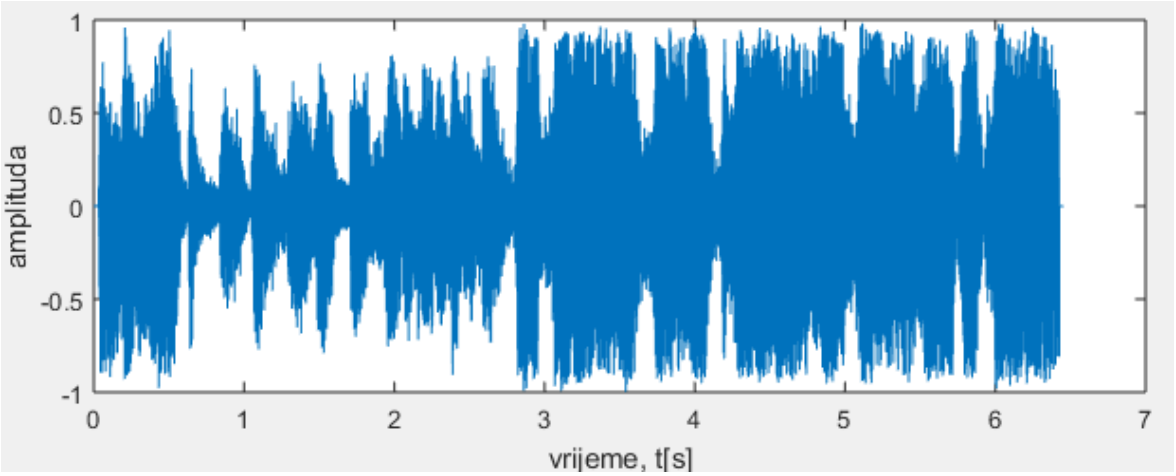
Rezultati točnosti za obrađene žanrove su vidljivi u tablici 3.3.

Po relativnoj točnosti je vidljivo kako podudarnost metode otkucaja i Scheirerove metode ovisi od pojedinog žanra, dok je za neke skoro stopostotan, za neke je tek na pola prosječne vrijednosti.

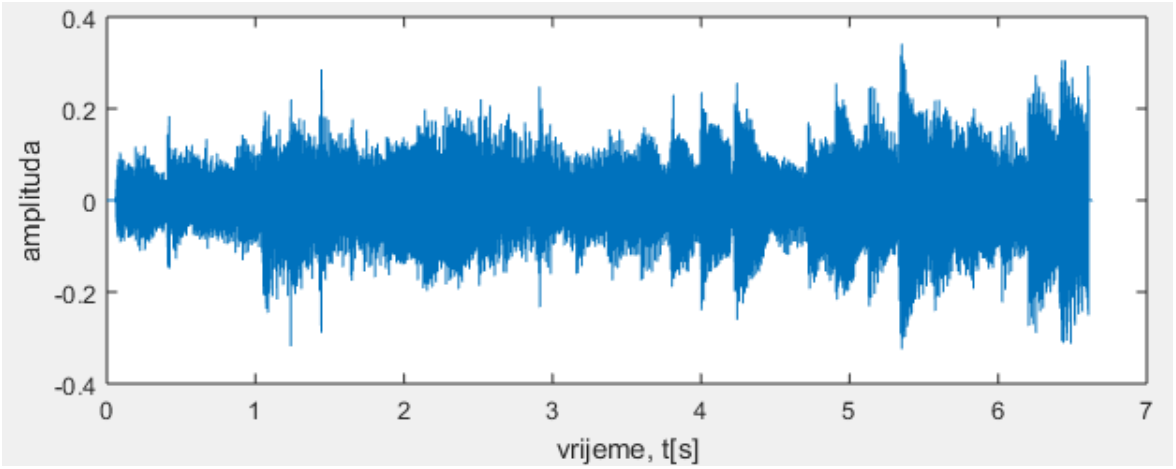
Glazbeni žanr	**Prosječan rezultat BPM**	**Prosječna pogreška S.M. u odnosu na M.O.**	**Relativna točnost A [%]**
Glazba afričkog podrijetla	118,50	33,00	73,71
Glazba azijskog podrijetla	103,97	20,19	48,89
Blues	119,75	65,38	49,62
Klasična glazba	190,31	38,25	76,81
Country	120,31	28,38	75,60
Dance/electronic	169,63	2,63	98,55
Domaći pop	111,25	38,25	68,10
Domaći rock	124,72	56,44	57,62
Folk	112,28	22,19	81,40
Izvorna glazba	152,25	81,37	34,83
Jazz	152,38	77,38	42,44
Latino	96,31	15,50	85,10
Pop	125,31	47,38	55,08
R&B	114,22	54,31	52,64
Rap	92,22	26,31	77,57
Rock	137,69	39,00	75,69
Ukupno	**127.57**	**40.69**	**65.85**

Tab. 3.3. Rezultati podudarnosti Scheirerove metode i metode otkucaja prema žanru

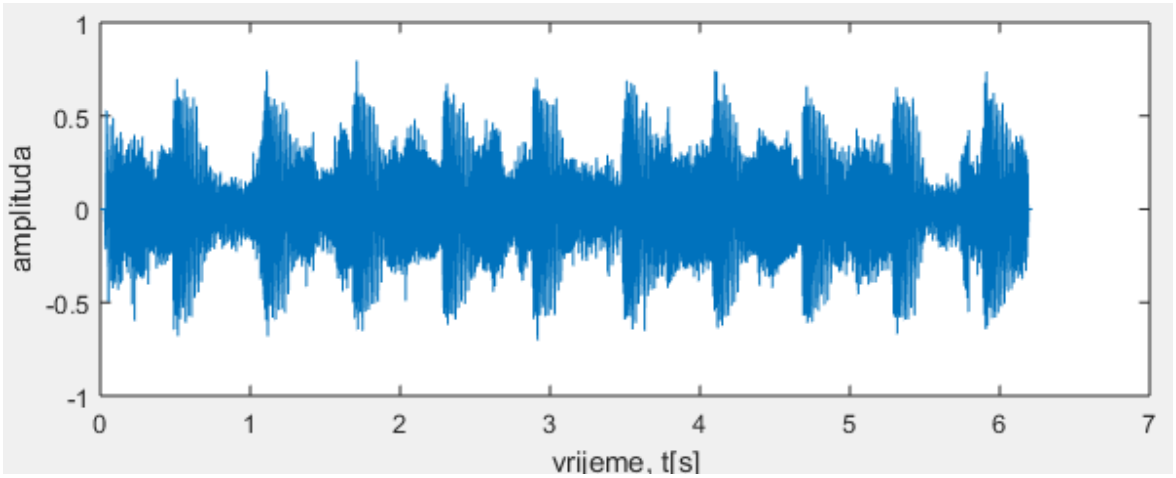
Razlog tih velikih odstupanja je moguće i vidjeti ako se pogledaju samo valni oblici za nekoliko karakterističnih glazbenih signala.



Sl. 3.1. Prikaz valnog signala za izvornu glazbu



Sl. 3.2. Prikaz valnog signala za klasičnu glazbu



Sl. 3.3. Prikaz valnog signala za dance/electronic glazbeni žanr

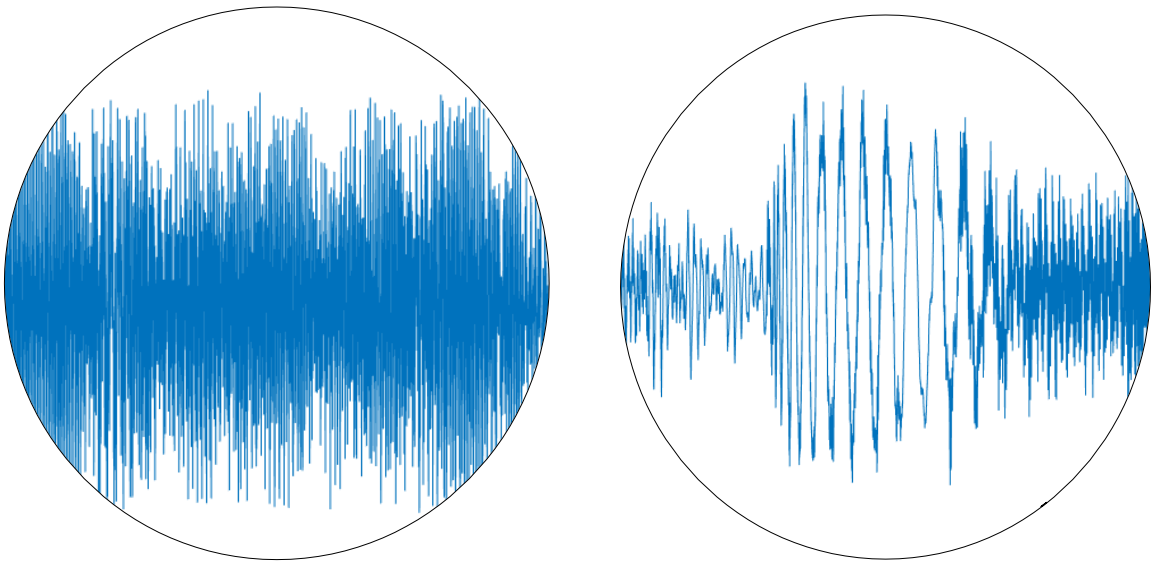
Usporede li se prikazi valnih oblika glazbenog signala sa slika 3.1, 3.2. i 3.3. na prvi pogled su uočljive neke razlike. Za bolju usporedbu je uzet jednak raspon vrijednosti po vremenskoj osi. Tim je spriječeno razvlačenje signala, a samim tim i naizgled njegovo poboljšanje.

Pogled na valni oblik glazbenog signala izvorne glazbe (Sl. 3.1.) ostavlja dojam signala koji na trenutke daje obojeni pravokutnik, zatim promjenu te opet obojeni pravokutnik. Amplituda gotovo tijekom cijelog vremenskog intervala doseže vrijednost blisku 1.

Nasuprot valnom obliku glazbenog signala izvorne glazbe, valni oblik glazbenog signala klasične glazbe (Sl. 3.2.) ima više nego dvostruko manju amplitudu. Također je uočljiva i razlika "manje pravokutnika". Cijela skladba je odsvirana samo na jednom instrumentu što joj daj jasnoću prikazanu u vidu više špicastog signala.

Najveća razlika je vidljiva između valnog oblika glazbenog signala izvorne glazbe te dance/electronic glazbe. Na slici 3.3. se uočljivo vidi rastavljanje signala na niže i više amplitude te njihov relativni kontinuitet i periodičnost. Čak i na klasičnom prikazu dance/electronic signala je vidljiv razmak i između njegovih najbližih vrhova.

Za bolje uočavanje razlika u valnim oblicima je na slici 3.4. prikazan uvećani prikaz dijela signala sa slike 3.1. i sa slike 3.3.



Sl. 3.4. Uvećani prikaz signala sa slike 3.1.(lijevo) i signala sa slike 3.3.(desno)

Primjetno je kako signalu sa slike 3.1. nije pomoglo ni uvećavanje tako što se vremenska os razvukla na samo jednu, umjesto sedam sekundi. Signal je i dalje vrlo zbijen, samo malo manje nego valni oblik glazbenog signala za dance/electronic na intervalu od 7 sekundi.

Dok je na slici 3.4. desno vidljivo uvećanje valnog oblika glazbenog signala dance/electronic na intervalu od jedne sekunde, koji je očita razlika od signala lijevo. Signal je jednoznačniji, u većoj mjeri izgleda kao jedna izlomljena crta. To je jako bitno pri obradi signala. Računalo ima mnogo manju mogućnost pogreške jer je signal jednoznačan te na jednom te istom mjestu neće imati mogućnost biranja od više vrijednosti signala. Zbog tog je računalna obrada ovakvih signala podudarna s metodom otkucaja.

Za računalnu obradu bi bilo pogodno kada bi svi signali bili jednoznačni, ali većina njih gubi tu karakteristiku zbog raznih šumova pri nastanku istog. Šum bi se mogao odstraniti poznatim metodama za uklanjanje šuma iz govornih i akustičnih signala koje razdvajaju šum od akustičnog dijela, jeke i samog glasa.

Takve metode se najčešće upotrebljavaju za lakše razumijevanje glasa iz loših snimaka kao što su na primjer avionske nesreće i ratovi, ali bi se mogle upotrijebiti i u ovom slučaju, samo što bi se važnost davala akustičnom dijelu, a ostali dijelovi bi se zanemarili.

Metode za pročišćavanje signala nisu tako jednostavne i kratkotrajne, a kako se u ovom slučaju radi o dosta mjerenja i dosta čestim mjerenjima od strana osoba kojima su potrebni rezultati, takvi koraci se preskaču te se za dovoljnu pouzdanost uzima onoliko koliko daje program i ljudsko uho.

4. ZAKLJUČAK

Svrha ovog rada je na što vjerodostojniji način odrediti koliko bita u minuti (BPM) ima u pojedinoj glazbi. Kako bi se pridonijelo pronalasku što točnijeg tempa izvršeno je istraživanje s dvije različite metode: metodom tipkanja i Scheirerovom metodom.

Metoda tipkanja je najjednostavnija, ima prost kod, jednostavna je za razumjeti i isprogramirati, ali pri radu tog koda je potrebno da osoba sluša glazbu te kuca tempo. To dovodi do upitnosti metode o tome tko kuca tempo jer nisu sve osobe jednako muzikalne. Glazbeno obrazovanija osoba će za ovu metodu svakako dati bolje rezultate, nego glazbeno nepismena osoba.

U pokušaju izbjegavanja potrebe za muzikalnošću osobe urađene su metode za koje se unosom glazbenog signala u valnom obliku u program može odrediti količina BPM.

Scheirer je osmislio metodu s šest eliptičnih filtara koji daju računalne rezultate bez obzira na izvođača pokusa, ali samim tim je kompliciranija izvedba, kompliciraniji je kod, kompliciranije je mjerenje te odlučivanje ispravnog tempa na samom kraju.

Zavisno od potreba, mogućnosti korisnika te važnosti točnosti rezultata mogu se upotrebljavati obje metode. Scheirerova metoda je praktična kod glazbenih signala koji pripadaju modernoj glazbi jer je njen tempo najčešće određen basom ili udaraljkama.

Najveći problemi Scheirerove metode su određivanje tempa koji nije određen samo jednim instrumentom, u najgorem slučaju kada je određen nekim instrumentom i bubnjem. Program tada ne detektira pravilan tempo nego samo bubnjeve. Pogreške se pojavljuju također i suprotno, tj. da metoda prepoznaje preveliki neistiniti tempo. Takvo što se najviše događalo kod jazz i izvorne glazbe gdje tempo određuje nekoliko instrumenata koji sviraju istovjetni tempo, ali budući da nije idealno vrijeme "istovremenog" sviranja program detektira 2, 3 ili više puta uvećan tempo, za svaki instrument po jedan put više. Kod glazbe čiji su snimci iz ranijih doba dok je snimana i velika količina šumova, a nikada nisu ponovno snimljeni također dolazi do pogreške zbog nejasnoće signala, izmjene amplitude, a na velikom dijelu i neprepoznatljivosti oblika signala uopće.

Proces izbjegavanja navedenih pogrešaka je najjednostavniji ako se za obradu uzmu samo instrumentalne verzije istih pjesama, u najboljem slučaju odsvirane na jednom instrumentu, Scheirerova metoda tada ima neznatne greške, koje se mogu zanemariti.

Broj otkucaja u minuti je najčešće potreban DJ-evima pri kombiniranju dvije vrste glazbenog signala kako bi dobili neki inovativni i zabavniji zvuk. Isto tako je poznato da se uglavnom bave dance/electronic glazbom, onda je Scheirerova metoda sasvim pogodna.

U slučajevima kada je ipak potrebno ukomponirati i neki klasičniji i stariji žanr u nešto noviji signal, preporučuje se metoda otkucaja. Metoda otkucaja u tom je slučaju bolja jer su to signali koji su nastali čisto analognim putem, dakle ljudskim glasom i sviranjem instrumenta, a i detektor tog signala je analogan(ljudsko uho). Dok za glazbu koja velikim dijelom nastaje radom računala, tj. kao digitalni signal, su upotrebljive obje metode.

LITERATURA

[1] J. Tomac Jovanović, *"Rizično ponašanje i izloženost buci među adolescentima"*, Sveučilište u Zagrebu, Medicinski fakultet, Zagreb, 2015.
Dostupno na linku:
https://zir.nsk.hr/islandora/object/mef:648 (pristup ostvaren 24.05.2017.)

[2] T. Herberger, T. Tost, G. Flemming, *"System and method of BPM determination"*, Magix Entertainment Products, Gmbh, 2003.
Dostupno na linku:
https://www.google.com/patents/US6518492 (pristup ostvaren 23.06.2017.)

[3] Fakultet elektrotehnike i računarstva, Zagreb, *"Fourierova transformacija"*
Dostupno na linku:
https://www.fer.unizg.hr/_download/repository/3_fourierova_transformacija.pdf
(pristup ostvaren 01.05.2017.)

[4] Wikipedia, *"Fourier series"*
Dostupno na linku:
https://en.wikipedia.org/wiki/Fourier_series (pristup ostvaren 31.07.2017.)

[5] S. Bilbao, *"Numerical sound synthesis"*, Wiley, 2009.

[6] M. Karjalainen, T. Tolonen, *"Multi-pitch and periodicity analysis model for sound separation and auditory scene analysis"* , Helsinki University of Technology, Laboratory of Acoustics and Audio Signal Processing, 2015.
Dostupno na linku:
https://www.ee.columbia.edu/~dpwe/papers/KarjT99-pitch.pdf (pristup ostvaren 24.05.2017.)

[7] F. Gouyon, A. Klapuri, S. Dixon, M. Alonso, G. Tzanetakis, C. Uhle, *"An experimental comparison of audio tempo induction algorithms"*, International Conference on Music Information Retrieval (ISMIR 2004.), University Pompeu Fabra, Barcelona, Spain, 2004.
Dostupno na linku:
http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.92.8210&rep=rep1&type=pdf
(pristup ostvaren 26.05.2017.)

[8] F. Gouyon, A. Klapuri, S. Dixon, M. Alonso, G. Tzanetakis, C. Uhle, P. Cano, *"An Experimental Comparison of Audio Tempo Induction Algorithms"*, International Conference on Music Information Retrieval (ISMIR 2004), University Pompeu Fabra, Barcelona, Spain, 2004.
Dostupno na linku:
http://www.cs.tut.fi/sgn/arg/klap/gouyon-taslp-2006.pdf (pristup ostvaren 24.05.2017.)

[9] A. P. Klapuri, A. J. Eronen, J. T. Astola, *"Analysis of the meter of acoustic musical signals"*, IEEE Trans. Speech and Audio Proc., 2004.
Dostupno na linku:
http://www.cs.tut.fi/sgn/arg/klap/sapmeter.pdf (pristup ostvaren 15.08.2017.)

[10] O. Lartillot, P. Toiviainen, *"A Matlab Toolbox for Musical Feature Extraction From Audio"*, International Conference on Digital Audio Effects, Bordeaux, 2007.
Dostupno na linku:
https://www.jyu.fi/hytk/fi/laitokset/mutku/en/research/materials/mirtoolbox/MIRtoolbox1.5Guide (pristup ostvaren 15.08.2017.)

[11] K. Cheng, B.Nazer, J. Uppuluri, R. Verret , *"A beat synchronization"*
Dostupno na linku:
https://www.clear.rice.edu/elec301/Projects01/beat_sync/beatalgo.html
(pristup ostvaren 26.06.2017.)

SAŽETAK

U ovom radu objašnjeno je kako se Fourierovom transformacijom i autokorelacijskom funkcijom mogu obrađivati glazbeni signali. Pritom je cilj odrediti glazbeni tempo iz signala pomoću udaljenosti između dva susjedna vrha u glazbenom signalu. Obrađene metode daju rezultate o tempu preko različitih vrsta i količina filtra. Rezultati su ovisni o metodi i vrsti signala, a u mjerenju se upotrijebilo 16 različitih glazbenih žanrova. Mjerenja se vrše računalnom obradom signala dijelom u online izvedbama, a većim dijelom u programu Matlab. Metode koje su korištene u usporednim mjerenjima su metoda otkucaja i Scheirerova metoda.

Ključne riječi: tempo, bpm, glazbeni signal, Fourier, metoda, otkucaja, Tolonen, Karjalainen, Scheirer

ABSTRACT

TEMPO AND BEAT ESTIMATION OF MUSICAL SIGNALS

This paper explains how Fourier's transformation and autocorrelation function can process musical signals. The purpose is to define the musical pitch of the signal by the distance between the two neighboring peaks in the musical signal. The methods used give tempo results across different types and quantities of filters. Results depend on the method and type of signal and in measurements are used 16 different music genres. Measurements are performed by computer processing of the signal partly in online performances and mostly in Matlab. The methods used in comparative measurements are the tap method and Scheirer's method.

Key words: tempo, bpm, musical signal, Fourier, tap, method, Tolonen, Karjalainen, Scheirer

POPIS I OPIS UPOTRIJEBLJENIH KRATICA

A[%] – prosječna relativna točnost

BPM – broj otkucaja u minuti

DC komponenta – istosmjerna komponenta

DJ – (*eng. deejay*) – osoba koja kombinira najčešće dva glazbena signala, obično služeći se glazbenim pločama)

F.t. – Fourierova transformacija

M.O. – metoda otkucaja

R[%] – relativna točnost

R&B – glazbeni žanr ritam i blues

S.M. – Scheirerova metoda

ŽIVOTOPIS

Irena Mostarac rođena je 25.08.1995. u Žepču, Bosna i Hercegovina. Osnovnu školu započinje 2002. godine u osnovnoj školi "Vinište", a završava 2010. u osnovnoj školi "Žepče". Nakon osnovne škole upisuje Tehničare za mehatroniku u srednjoškolskom centru "KŠC Don Bosco" Žepče. Po završetku srednje škole, 2014. godine upisuje "Fakultet elektrotehnike, računarstva i informacijskih tehnologija" u Osijeku, odabire preddiplomski studij elektrotehnike, a nakon godinu dana se usmjerava na komunikacije i informatiku.

Potpis:

_____

PRILOG – DETALJNI REZULTATI MJERENJA

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Ali Farka Toure-Diaraby	180	189	95,24
Amadou & Mariam - Se-ne-gal Fast Food	62	170	36,47
Aster aweke- Mezez Alew	82	158	51,90
Fela Kuti - Sorrow, Tears and Blood	74	105	70,48
Femi Kuti - If Them Want To Hear	182	194	93,81
Prince Nico Mbarga -Sweet Mother	91	89	97,75
Fula Flute Kaira	230	225	97,78
Habib Koite - Batoumambe	82	109	75,23
Jah Bouks - Angola	62	83	74,70
Kanté Manfila et Salif Keïta - Tara	117	115	98,26
Mory Kanté - Yeke Yeke	94	87	91,95
Kankou - Nene Koita	61	105	58,10
Thione Seck - Raam Daan - Mathiou	82	96	85,42
Vieux Farka Touré - Ana	230	105	0,00
African music - Why	77	96	80,21
Youssou Ndour et le Super Etoile - Moor Ndaje	67	93	72,04

Tab. P1.1. Rezultati za glazba afričkog podrijetla

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Amrit Maan, Jasmine Sandlas, DJ Flow - Bamb Jatt	216	135	40,00
Jab Harry - Beech Beech	230	221	43,44
Enna Sona, Controlla, Satvik B - Bollywood	61	73	0,00
Mustafa & Kiara Advani - Cheez Badi	74	85	0,00
Deep Sukh ft. the Boss - Dial	69	92	83,70
Mankirt Aulakh Feat Deep Kahlon - Gangland	67	63	0,00
Guru Randhawa- High Rated Gabru	69	93	87,10
Parmish Verma - Hostel	68	85	91,76
Goldboy, Nirmaan - Yhooth	79	80	91,25
Diljit Dosanjh - Laembadgini	67	78	91,03
Mani Chuhan- Aakad	62	69	0,00
Pehli Nazar - Mere Rashke Qamar	193	110	88,18
Azhar – Oye Oye	198	202	85,64
Ammy Virk - Qismat	69	89	0,00
Jab Harry- Radha	91	101	80,2
Sharry Mann, Mista Baaz - Saade Aala	66	72	0,00

Tab. P1.2. Rezultati za glazbu azijskog podrijetla

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Albert King - Born Under A Bad Sign	70	88	79,55
Albert King - Crosscut Saw	96	120	80,00
B.B. King - The Thrill Is Gone	231	88	0,00
B.B. King- Everyday I have the Blues	234	101	0,00
Blues Brothers - Sweet Home Chicago	77	90	85,56
Bobby's Stormy Monday	193	58	0,00
Buddy Guy - Five Long Years	81	79	97,47
Derek & the Dominos - Key to the Highway	92	75	77,33
Donnie Ray - Rock Me Baby	73	93	78,49
Freddie King - Hideaway	71	82	86,59
Freddie King - I Just Want To Make Love to You	182	65	0,00
Gary B.B. Coleman - The Sky is Crying	123	112	90,18
Howlin Wolf - Spoonful	231	120	7,50
I'm Your Hoochie Coochie Man - Muddy Waters	207	127	37,01
Joe Bonamassa - Reconsider Baby	121	163	74,23
John Lee Hooker - Boom Boom	229	60	0,00

Tab. P1.3. Rezultati za blues

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Beethoven - Egmont Overture	218	190	85,26
Beethoven-Fur Elise	230	226	98,23
Beethoven - Symphony No. 5	206	209	98,56
Bizet - Carmen Suite No.1	205	135	48,15
Cajkovski- Swan lake	174	175	99,43
Carl Orff - O Fortuna - Carmina Burana	218	181	79,56
Chopin - Nocturne op.9 No.2 - Andante	230	208	89,42
Richard Wagner - Ride of the Valkyries	208	208	100,00
Edvard Grieg - Peer Gynt Suite No.1	217	237	91,56
Gioachino Rossini - The Barber Of Seville - Overture	220	220	100,00
Gustav Holst - Jupiter from 'The Planets'	93	168	55,36
Händel Messiah - Hallelujah Chorus	129	146	88,36
Johann Sebastian Bach - Orchestral Suite No. 3	236	57	0,00
Mozart - Piano Sonata No. 11 in a major	220	230	95,65
Offenbach - Barcarolle , from 'The Tales of Hoffmann'	180	181	99,45
Vivaldi - Autumn from 'The Four Seasons'	95	240	78,48

Tab. P1.4. Rezultati za klasičnu glazbu

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Billy Currington - Do I Make You Wanna	74	83	89,16
Blake Shelton - Every Time I Hear That Song	137	155	88,39
Brett Young - In Case You Didn't Know	216	176	77,27
Brothers Osborne - It Ain't My Fault	92	118	77,97
Chris Lane - For Her	172	179	96,09
Cole Swindell - Flatliner feat. Dierks Bentley	156	118	67,80
Dustin Lynch - Small Town Boy	230	135	29,63
Dylan Scott - My Girl	145	166	87,35
Jason Aldean - They Don't Know	64	85	75,29
Jon Pardi - Heartache On The Dance Floor	88	115	76,52
Justin Moore - Somebody Else Will	68	73	93,15
Kane Brown - What Ifs ft. Lauren Alaina	109	112	97,32
Keith Urban - The Fighter ft. Carrie Underwood	98	108	90,74
Lady Antebellum - You Look Good	60	71	84,51
Luke Combs - Hurricane	62	79	78,48
Midland - Drinkin' Problem	206	100	0,00

Tab. P1.5. Rezultati za country

Ime izvođača, pjesme	BPM S.M.	BPM M.O	R [%]
Axwell - Ingrosso - More Than You Know	240	243	98,77
Calvin Harris – Feels ft. P.Williams, K.Perry, Big Sean	183	188	97,34
Calvin Harris - Rollin ft. Future, Khalid	231	233	99,14
Calvin Harris - Slide ft. Frank Ocean, Migos	83	83	100,00
Cheat Codes - No Promises ft. Demi Lovato	86	84	97,62
Clean Bandit - Rockabye ft. Sean Paul & Anne-Marie	239	234	97,86
Clean Bandit - Symphony feat. Zara Larsson	144	142	98,59
David Guetta ft Justin Bieber - 2U	115	116	99,14
DJ Snake ft. Justin Bieber - Let Me Love You	217	214	98,60
Jonas Blue - Mama ft. William Singe	230	229	99,56
Katy Perry - Swish Swish) ft. Nicki Minaj	163	158	96,84
Kygo, Selena Gomez - It Ain't Me	216	220	98,18
Major Lazer - Know No Better ft. T. Scott, C. Cabello, Quavo	231	224	96,88
Martin Garrix - Scared To Be Lonely feat. Dua Lipa	103	103	100,00
Martin Garrix & Troye Sivan - There For You	102	103	99,03
The Chainsmokers - Closer ft. Halsey	136	135	99,26

Tab. P1.6. Rezultati za dance/electronic

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Colonia - Plamen od ljubavi	91	121	75,21
Dino Merlin - Sve do medalje	193	81	0,00
Erato & Jacques Houdek - Putujemo snovima	162	108	50,00
Hari Mata Hari - Da ti k'o čovjek oprostim	81	99	81,82
Jacques Houdek – Zauvijek tvoj	85	109	77,98
Jasmin Stavros & Učiteljice - Nema natrag	216	125	27,20
Jole - Kada Žene Tulumare	97	132	73,48
Mejaši – Zavela me Ana	60	158	37,97
Poslednja Igra Leptira - Nataša	102	103	99,03
S.A.R.S. - Lutka	93	85	90,59
Toni Cetinski - Jednom u zivotu	77	93	82,80
Toni Cetinski - Zena nad zenama	205	156	68,59
Valentino - Mirise Mi Mirise	74	110	67,27
Zdravko Colic - Mjerkam te, mjerkam	68	84	80,95
Željko & Daniel – Skoplje Beograd	79	103	76,70
Željko Samardži- - Nije moje da znam	105	105	100,00

Tab. P1.7. Rezultati za domaći pop

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Alisa - Kesten	97	116	83,62
Azra - Voljela me nije nijedna	212	177	80,23
Bijelo dugme - Na zadnjem sjedištu moga auta	90	120	75,00
Divlje Jagode - Samo da znaš	205	72	0,00
Ekatarina Velika - Par godina za nas	205	96	0,00
Kerber - Ratne igre	88	94	93,62
Neki To Vole Vruće - California	185	169	90,53
Opća opasnost - Treba mi nešto jače od sna	63	181	34,81
Osvajači - Gde da pobegnem	69	189	36,51
Parni Valjak - Sve jos miriše na nju	163	115	58,26
Prljavo kazalište - Tu noć kad si se udavala	68	68	100,00
Riblja Čorba - Jedino moje	62	92	67,39
Smak - Daire	77	109	70,64
Viktorija - Rat I Mir	13	103	12,62
Zabranjeno Pušenje - Karabaja	204	144	58,33
Željko Bebek - Mene tjera neki vrag	201	144	60,42

Tab. P1.8. Rezultati za domaći rock

Ime izvođača, pjesme	BPM S.M.	BPM M.O	R [%]
Mile Kitić - Luda devojko	204	168	78,57
Aco Pejović - Jelena	181	157	84,71
Ana Nikolić - Mišo moj	102	121	84,30
Ceca-Tačno je	68	85	80,00
Dejan Matić - Bitanga i dama	77	95	81,05
Ivana Selakov - Grad grad	93	112	83,04
Jelena Rozga - Dobitna kombinacija	105	108	97,22
Mia Borisavljević - Luda glava	61	161	37,89
Mia Borisavljević – Gruva gruva	92	119	77,31
Milan Mitrović - Raspad sistema	76	94	80,85
Milan Dinčić Dinča ft. Olja Bajrami – Promaja u glavi	153	153	100,00
Milica Todorović – Tri čaše	183	185	98,92
Ministarke feat Aco Pejovic - Poplava	78	96	81,25
Nedeljko Bajić Baja - Od Ljubavi Jače	60	79	75,95
Ok band - Najbolje žene	74	90	82,22
Rada Manojlović - Nije meni	72	91	79,12

Tab. P1.9. Rezultati za folk

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Bekrije - Garavušo garava	230	163	58,9
Braća Begić - Tebi pjevam Posavino mila	223	110	0,00
Braca Geljić - Kad Se Sjetim Starih Običaja	96	130	73,85
Braca Geljić - Zet Nasljednik	204	124	35,48
Gazde - Ja pijem da zaboravim	230	181	72,93
Gazde - Još i danas zamiriše trešnja	230	124	14,52
Miroslav Škoro - Da Sam Im'o Šaku Dukata	223	87	0,00
Miroslav Škoro - Kuća na kraju sela	221	97	0,00
Miroslav Škoro - Ne dirajte mi ravnicu	181	89	0,00
Miroslav Škoro - Juliska	60	136	44,12
Miroslav Škoro - Konji bili, konji vrani	229	89	0,00
Miroslav Škoro - Mata	224	115	5,22
Miroslav Škoro - Otvor ženo kapiju	104	102	98,04
Klapa Cambi - Ne more mi bit	193	82	0,00
Bistri izvor - Selo moje sve me tebi zove	223	178	74,72
Slavonske lole - Duša bećarska	106	88	79,55

Tab. P1.10. Rezultati za izvornu glazbu

Ime izvođača, pjesme	BPM S.M	BPM M.O	R [%]
All Blues- Miles Davis	223	143	44,06
Billie Holiday - Body And Soul	211	58	0,00
Billie Holiday - Strange Fruit	121	122	99,18
Charles Mingus - Goodbye Pork Pie Hat	66	64	96,88
Dave Brubeck - Take Five	68	138	49,28
Duke Ellington - Satin Doll	240	130	15,38
Duke Ellington - Take the 'a' train	65	170	38,24
Ella Fitzgerald - How High The Moon	203	128	41,41
Eric Clapton -Autumn Leaves	205	83	0,00
Frank Sinatra - My Funny Valentine	217	100	0,00
Frank Sinatra Fly Me To The Moon	164	120	63,33
Duke Ellington and John Coltrane - In a Sentimental Mood	217	144	49,31
Bobby Darin - Mack the Knife	216	188	85,11
Miles Davis - Freddie Freeloader	234	132	22,73
Miles Davis - On Green Dolphin Street	235	171	62,57
Duke Ellington - Mood Indigo	196	104	11,54

Tab. P1.11. Rezultati za jazz

Ime izvođača, pjesme	BPM S.M.	BPM M.O	R [%]
Chris Jeday - Ahora Dice ft. J. Balvin, Ozuna, Arcángel	193	190	98,42
CNCO - Hey DJ	66	77	85,71
Conor Maynard, Anth - Mi Gente	78	79	98,73
Danny Ocean - Me Rehúso	86	93	92,47
El Amante - Nicky Jam	67	77	87,01
Enrique Iglesias - Subeme la Radio ft. D. Bueno, Zion, Lennox	122	126	96,83
J. Balvin - Si Tu Novio Te Deja Sola ft. Bad Bunny	142	123	84,55
J. Balvin - Sigo Extrañándote	69	91	75,82
Karol G, Bad Bunny - Ahora Me Llama	91	83	90,36
Daddy Yankee ft Ozuna - La Rompe Corazones	65	85	76,47
Luis Fonsi - Despacito ft. Daddy Yankee	66	93	70,97
Maluma - Felices los 4	70	85	82,35
Mayores - Becky G ft. Bad Bunny	72	97	74,23
Nacho - Bailame	71	95	74,74
Prince Royce, Shakira - Deja vu	86	118	72,88
Romeo Santos - Imitadora	103	123	100,00

Tab. P1.12. Rezultati za latino glazbu

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Adele - Hello	192	64	0,00
Britney Spears - Baby One More Time	240	112	0,00
Charlie Puth - Attention	60	92	65,22
Ed Sheeran - Shape of You	72	87	82,76
Justin Bieber - Sorry	73	100	73,00
Katy Perry - Dark Horse ft. Juicy J	216	133	37,59
Liam Payne - Strip That Down ft. Quavo	228	207	89,86
Mark Ronson - Uptown Funk ft. Bruno Mars	83	117	70,94
Michael Jackson - Billie Jean	173	131	67,94
OMI - Cheerleader	91	118	77,12
Pharrell Williams - Happy	60	75	80,00
Rihanna - We Found Love ft. Calvin Harris	216	213	98,59
Shawn Mendes - There's Nothing Holdin' Me Back	91	124	73,39
Sia - Cheap Thrills ft. Sean Paul	67	87	77,01
Taylor Swift - Wildest Dreams	101	115	87,83
Whitney Houston - I Will Always Love You	204	68	0,00

Tab. P1.13. Rezultati za pop

Ime izvođača, pjesme	BPM S.M.	BPM M.O.	R [%]
Adina Howard - Freak Like Me	99	96	96,88
Blackstreet - No Diggity ft. Dr. Dre, Queen Pen	235	90	0,00
Blue - U Make Me Wanna	60	76	78,95
Boyz II Men - End Of The Road	182	126	55,56
Boyz II Men - Motownphilly	86	62	61,29
Color Me Badd - I Wanna Sex You Up	76	97	78,35
Destiny's Child - Say My Name	122	69	23,19
Donell Jones - U Know What's Up	80	90	88,19
Easton Corbin - Let's Ride	204	135	48,89
Ginuwine - Pony	240	147	36,73
K-Ci & JoJo - All My Life	95	96	98,96
Montell Jordan - This Is How We Do It	240	108	0,00
R. Kelly-Bump 'n' Grind	162	65	0,00
Redbone Childish Gambino	62	88	70,45
Rome-Real Love	72	53	64,15
Shanice - I Love Your Smile	69	173	39,88

Tab. P1.14. Rezultati za R&B

Ime izvođača, pjesme	BPM S.M.	BPM M.O	R [%]
2Pac - Dear Mama	176	91	6,59
2pac feat Dr.Dre - California Love	70	131	53,44
50 Cent - In Da Club	71	71	100,00
Lil Wayne - Around The Way Girl	73	70	95,71
Black Sheep - The Choice Is Yours	76	87	87,36
Bone Thugs N Harmony – Crossroads	83	74	87,84
Dr. Dre - Still D.R.E. ft. Snoop Dogg	79	108	73,15
Drake - The Motto ft. Lil Wayne, Tyga	75	104	72,12
Eminem - Stan ft. Dido	114	114	100,00
Eminem - When I'm Gone	61	69	88,41
Jay Z - Empire State of Mind ft. Alicia Keys	64	69	92,75
Kanye West - Gold Digger ft. Jamie Foxx	225	56	0,00
Lil Wayne - Lollipop ft. Static	60	69	86,96
Naughty By Nature - O.P.P.	153	153	100,00
OutKast ft. Sleepy Brown - The Way You Move	62	62	100,00
Snoop Dogg - Drop It Like It's Hot ft. Pharrell Williams	89	92	96,74

Tab. P1.15. Rezultati za rap

Ime izvođača, pjesme	BPM S.M	BPM M.O.	R [%]
AC-DC - Highway to Hell	84	116	72,41
Aerosmith - Cryin'	204	154	67,53
Alice Cooper - School's Out	230	200	85,00
Jimi Hendrix - All Along The Watchtower	146	112	69,64
Deep Purple - Smoke on the Water	183	172	93,60
Free Bird - Lynyrd Skynyrd	230	58	0,00
Guns 'N' Roses - Welcome To The Jungle	91	248	36,69
Jimi Hendrix - American Woman	229	225	98,22
Journey - Don't Stop Believin'	84	112	75,00
Led Zeppelin - Stairway To Heaven	240	200	80,00
Nightwish - Moondance	123	135	91,11
Nirvana - Smells Like Teen Spirit	86	90	95,56
Pink Floyd - Another Brick In The Wall	73	104	70,19
Queen - Bohemian Rhapsody	78	78	100,00
R.E.M. - Losing My Religion	92	89	96,63
Stone Temple Pilots - Interstate Love Song	62	78	79,49

Tab. P1.16. Rezultati za rock