

Izdvajanje sekvenci glasanja šišmiša (Chiroptera) iz dugih nizova terenskih audio snimaka pomoću strojnog učenja

Hackenberger Kutuzović, Domagoj

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of biology / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za biologiju**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:181:159927>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-05-14**



Repository / Repozitorij:

[Repository of Department of biology, Josip Juraj Strossmayer University of Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ODJEL ZA BIOLOGIJU**

Diplomski sveučilišni studij: Zaštita prirode i okoliša

Domagoj K. Hackenberger

**IZDVAJANJE SEKVENCI GLASANJA ŠIŠMIŠA
(Chiroptera) IZ DUGIH NIZOVA TERENSKIH AUDIO
SNIMAKA POMOĆU STROJNOG UČENJA**

Diplomski rad

Osijek, 2017

Temeljna dokumentacijska kartica

Sveučilište Josipa Jurja Strossmayera u Osijeku Odjel za biologiju

Diplomski rad

Diplomski sveučilišni studij: Zaštita prirode i okoliša

Znanstveno područje: Prirodne znanosti

Znanstveno polje: Biologija

IZDVAJANJE SEKVENCI GLASANJA ŠIŠMIŠA (Chiroptera) IZ DUGIH NIZOVA TERENSKIH AUDIO SNIMAKA POMOĆU STROJNOG UČENJA

Domagoj Hackenberger Kutuzović

Rad je izrađen: Odjel za biologiju, Sveučilište Josipa Jurja Strossmayera u Osijeku, Zavod za kvantitativnu ekologiju

Mentor: dr. sc. Oleg Antičić, izv. prof.

Kontinuirano praćenje šišmiša (Chiroptera) na terenu rezultira nastankom dugih nizova terenskih audio snimaka. Ručni pregled ovih podataka zbog količine snimaka predstavlja vrlo zahtjevan zadatak. Kako bi se ubrzala analiza snimaka šišmiša izrađeni sustavi temeljeni na umjetnim neuronskim mrežama. Ovi sustavi imaju sposobnost automatskog izdvajanja sekvenci glasanja šišmiša iz dugih nizova audio snimaka.

Ključne riječi: Šišmiši, Chiroptera, Umjetne neuronske mreže, Detekcija, Ultrazvuk, Spektralna analiza, Strojno učenje

Broj stranica: 92

Broj slika: 51

Broj tablica: 8

Broj literaturnih navoda: 43

Broj priloga: 4

Jezik izvornika: Hrvatski

Datum obrane: 19. 4. 2017.

Stručno povjerenstvo za obranu:

1. dr. sc. Oleg Antičić, izvanredni profesor Odjela za biologiju Sveučilišta Josipa Jurja Strossmayera u Osijeku
2. dr. sc. Alma Mikuška, docentica Odjela za biologiju Sveučilišta Josipa Jurja Strossmayera u Osijeku
3. dr. sc. Goran Vignjević docent Odjela za biologiju Sveučilišta Josipa Jurja Strossmayera u Osijeku

Rad je pohranjen u:

Knjižnici Odjela za biologiju Sveučilišta Josipa Jurja Strossmayera i u Nacionalnoj sveučilišnoj knjižnici u Zagrebu, u elektroničkom obliku, te je objavljen na web stranici Odjela za biologiju.

Basic documentation card

Josip Juraj Strossmayer University of Osijek Department of Biology

Master degree thesis

Graduate university study programme in Nature and Environmental protection

Scientific Area: Natural science

Scientific field: Biology

BAT (Chiroptera) CALL SEQUENCE EXTRACTION FROM LONG SERIES OF FIELD AUDIO RECORDINGS USING MACHINE LEARNING

Domagoj Hackenberger Kutuzović

Thesis performed at: Department of Biology, Josip Juraj Strossmayer University of Osijek, Subdepartment of quantitative ecology

Supervisor: Oleg AntoniĆ, PhD, Associate Professor

Continuous field monitoring of Bats (Chiroptera) often results with long series of field audio recordings. Manual analysis of such footage is a demanding task. To facilitate analysis of bat call footage, systems based on artificial neural networks were created. These systems have the ability to extract sequences of bat calls from long series of field audio recordings.

Keywords: Bats, Chiroptera, Artificial neural networks, Detection, Ultrasound, Spectral analysis, Machine learning

Number of pages: 92

Number of images: 51

Number of tables: 8

Number of references: 43

Number of appendices: 4

Original in: Croatian

Date of thesis defense: 19.4.2017

Reviewers:

1. Oleg AntoniĆ, PhD, Associate Professor, Department of Biology, Josip Juraj Strossmayer University of Osijek
2. Alma Mikuška, PhD, Assistant Professor, Department of Biology, Josip Juraj Strossmayer University of Osijek
3. Goran VignjeviĆ, PhD Assistant Professor, Department of Biology, Josip Juraj Strossmayer University of Osijek

Thesis is deposited in Library of Department of Biology, Josip Juraj Strossmayer University of Osijek and in National university library in Zagreb in electronic form. It is also disposable on the web site of Department of biology, Josip Juraj Strossmayer University of Osijek.

Zahvala

Zahvaljujem se mentoru izv. prof. dr. sc. Olegu Antoniću na znanju i iskustvu koje mi je prenio tijekom izrade ovog diplomskog rada te na strpljenju i savjetima bez kojih ovaj rad ne bi bilo moguće izraditi.

Posebno hvala mag. oecol. et prot. nat. Dini Rnjak i ostalim članovima grupe za monitoring šišmiša tvrtke Geonatura d.o.o. koji su mi omogućili rad na ovoj problematici.

Veliko hvala mojem ocu na strpljivosti, razumijevanju i usmjeranju koje mi je pružio tijekom školovanja.

Hvala svim članovima Zavoda za kvantitativnu ekologiju na podršci tijekom izrade ovog diplomskog rada.

Hvala i svim drugima koji su posredno ili neposredno pomogli u realizaciji ovog rada.

Sadržaj

Temeljna dokumentacijska kartica.....	i
Basic documentation card	iii
Zahvala.....	v
1 Uvod	1
1.1 Ugroženost populacija šišmiša	5
1.2 Zvuk.....	8
1.2.1 Analiza zvuka.....	10
1.3 Analiza velikog skupa podataka - podatkovno rudarenje.....	13
2 Ciljevi istraživanja	15
3 Materijali i metode	17
3.1 Podaci	17
3.2 Prethodna obrada podataka	23
3.3 Izrada i treniranje modela za klasifikaciju pomoću SURF značajki.....	27
3.4 Validacija modela	31
4 Rezultati	33
4.1 Model 1.....	33
4.2 Model 2.....	33
4.3 Usporedba komercijalnih rješenja i izrađenih modela.....	34
4.4 Analiza pogreške klasifikacije.....	36
5 Rasprava	43
5.1 Primjena korištenih metoda	45
5.2 Nedostaci izrađenih modela	45
6 Zaključci	49
7 Literatura	51

8	Prilozi.....	55
8.1	Popis šišmiša Hrvatske	55
8.2	Informatičko okruženje za analizu snimaka ultrazvuka.....	57
8.2.1	Primjeri korištenja paketa:.....	57
8.3	Pregled specifičnih zvučnih zapisa iz skupa za treniranje modela	60
8.3.1	Šišmiši	60
8.3.2	Šumovi.....	77
8.4	Izvori slika.....	80


1 Uvod

Red šišmiša (Chiroptera) obuhvaća oko 1300 opisanih vrsta (Fenton i Simmons 2015). Tradicionalno se ovaj red dijeli na podredove Microchiroptera (mali šišmiši) i Megachiroptera (veliki šišmiši). Međutim, na temelju novijih, genetičkih, paleontoloških i ekoloških istraživanja, moguće je dodatno red podjeliti na podredove Yangochiroptera ili Vespertilioniformes i Yinpterochiroptera ili Pteropodiformes (Teeling 2005). Tako se u podred Yinpterochiroptera svrstavaju sve porodice reda Megachiroptera uz 5 dodatnih porodica iz reda Microchiroptera (Rhinopomatidae, Rhinolophidae, Hipposideridae, Craseonycteridae, i Megadermatidae), dok se u podred Yangochiroptera svrstavaju sve ostale porodice koje su bile uvrštene u podred Microchiroptera.

U cijeloj Europi je zabilježeno 43 vrste šišmiša (Barataud 2015) dok je u Hrvatskoj zabilježeno 35 vrsta šišmiša (Prilog *Tablica 8.1*) odnosno 81.4 % svih vrsta Europe. Jedna od 35 zabilježenih vrsta u Hrvatskoj, *Rhinolophus mehelyi*, smatra se regionalno izumrlom (Hutson 2008). Prema Crvenoj knjizi sisavaca Hrvatske (2008.) u kategoriju ugrožene vrste (EN) spadaju 3 vrste (*Plecotus austriacus*, *Myotis capaccinii* i *Miniopterus schreibersii*). U kategoriju rizične vrste (VU) spadaju također 3 vrste (*Rhinolophus blasii*, *Rhinolophus euryale* i *Myotis bechsteinii*). 5 vrsta šišmiša spadaju u kategoriju nedovoljno poznatih i vjerojatno ugroženih vrsta (DD) (*Barbastella barbastellus*, *Plecotus kolombatovici*, *Plecotus macrobullaris*, *Myotis dasycneme* i *Nyctalus lasiopterus*). Naposljetku u kategoriju potencijalno ugroženih vrsta (NT) spada još 5 vrsta (*Rhinolophus ferrumequinum*, *Rhinolophus hipposideros*, *Myotis emarginatus*, *Myotis myotis*, *Nyctalus leisleri*) (Anatolović i Tvrtković 2006). Stoga, ukupno 16 odnosno 44% vrsta šišmiša prisutno u Hrvatskoj pripadaju nekoj kategoriji ugroženosti prema IUCN-u. Ovakvi podaci ukazuju na značajnu raznolikost šišmiša i raznolikost prirodnih staništa u Hrvatskoj ali i na osjetljivost šišmiša na promjene stanja staništa. Sve vrste šišmiša zabilježene u Republici Hrvatskoj zaštićene su temeljem Zakona o zaštiti prirode (NN 70/05; 139/08) i Pravilnika o proglašenju divljih svojti zaštićenim i strogo zaštićenim (NN 99/09).

Sve vrste šišmiša u Hrvatskoj su prvenstveno insektivori te čine važan dio hranidbene mreže. Njihova aktivnost značajno utječe na populacije drugih vrsta poput primjerice

komaraca (Culicidae). *Nyctalus lasiopterus* jedina je vrsta šišmiša prisutna u Hrvatskoj koja se ishranu kukcima hrani i manjim pticama. Udio ptica u prehrani tijekom doba migracija ove vrste, može narasti i preko 80% (Popa-Lisseanu i sur. 2007). Unatoč uopćenom vjerovanju većini šišmiša vid nije oslabljen. Međutim, sam vid im nije dovoljan za orijentaciju u prostoru pogotovo prilikom lova tijekom noći ili orijentacije u špiljskim staništima. Kako bi se orijentirali u prostoru i locirali lovnu ili prijetnju šišmiši u grkljanu (lat. *larynx*) proizvode kratke glasove. Frekvencije tih glasova se obično kreću unutar raspona od 8 do 150kHz ovisno o vrsti. Glasovi koje šišmiši koriste za orijentaciju ne moraju nužno biti u valnom području ultrazvuka (Barataud 2015). Primjerice jedna od vrsta zastupljenih u Hrvatskoj, *Tadarida teniotis*, proizvodi glasove s frekvencijama ispod 20kHz, odnosno unutar za čovjeka slušljivog spektra frekvencija.



Slika 1.1 Pojednostavljeni grafički prikaz principa eholokacije: (1) - šišmiš; (2) - lovina; (3) - ultrazvuk koji šišmiš odašilje; (4) - povratna informacija u obliku jeke

Prilikom propagacije ti se zvuci reduciraju s obzirom na udaljenost i akustična svojstva zraka. Nakon što zvučni signal dođe do objekta on se od njega odbija. Način odbijanja zvuka od objekta ovisi o obliku, teksturi površine, mekoći pa i brzini kretanja objekta (Dopplerov efekt). Svi ti čimbenici rezultiraju jekama koje se vraćaju u slušni aparat šišmiša. Šišmiši usporedbom jeke koju čuju i glasa koji su proizveli dobivaju sve potrebne informacije o udaljenosti objekata oko sebe (Slika 1.1).

Stručnjaci koji se bave ekologijom i biologijom šišmiša ulažu puno vremena i truda u učenje raspoznavanja akustičnih zapisa glasova šišmiša vlastitim sluhom (tzv. ekspertna interpretacija i klasifikacija zvučnog zapisa ili kraće „ručna klasifikacija“).

Kako svaki čovjek zvukove doživljava subjektivno nameće se pitanje preciznosti identifikacije šišmiša takvom metodom. Ipak, ovakav pristup je danas najčešći način identifikacije šišmiša. Europske vrste šišmiša proizvode glasove koji se mogu klasificirati na temelju izmjene frekvencije glasa tijekom vremena u tri osnovne klase: klasa frekvencijski modulirajućih (FM) glasova, klasa glasova djelomično-konstantnih frekvencija (QCF) i klasa glasova konstantnih frekvencija (CF) (Slika 1.2). FM glasove ispuštaju sve vrste Europskih šišmiša osim šišmiša iz roda *Rhinolophus* čiji glasovi pripadaju u CF kategoriju. Specifično glasanje vrsta ovog roda rezultat je različitog anatomske i morfološke prilagodbe za emitiranje zvuka. Za razliku od ostalih šišmiša koji se koriste eholokacijom i zvuk ispuštaju kroz usta pripadnici roda *Rhinolophus* ispuštaju zvuk kroz posebno prilagođen nos (Slika 1.3). Isključivo FM glasanje specifično je za vrste rodova *Myotis* i *Plecotus*. Dok je glasanje i FM i QCF tipovima glasova zabilježeno kod rodova *Nyctalus*, *Eptesicus*, *Vespertilio*, *Pipistrellus*, *Barbastella*, *Miniopterus* i *Tadarida* (Barataud 2015).

Ručna klasifikacija šišmiša se u najnovije vrijeme izvodi na način da se uz pomoć različitih računalnih programa za vizualizaciju zvučnih glasova šišmiša proizvedu spektrogrami (kao grafičke vizualizacije zvučnog signala). Analizom tako dobivenih spektrograma, preslušavanjem snimki i uporabom specijaliziranih statističkih ključeva za identifikaciju (Barataud 2015) određuje se prisutna vrsta. Kvaliteta identifikacije ovim pristupom značajno ovisi o kvaliteti snimke i iskustvu korisnika.

Analizom eholokacijskih glasova šišmiša moguće je identificirati i locirati šišmiše u prostoru. Analiza zvukova šišmiša može ukazati na vrstu ponašanja vrste te dati korisne podatke o ekologiji pojedine vrste. Jedan od načina prikupljanja podataka o šišmišima, primjerice na području rada vjetroelektrana je kontinuirano snimanje zvuka. Pri takvom snimanju detektori bilježe moguće zvučne signale šišmiša u ultrazvučnom spektru. Bilo zbog promjenjivih uvjeta u okolišu bilo zbog mnogih nepredviđenih izvora ultrazvuka, kontinuirano snimanje rezultira nastankom velikog skupa podataka koji uz zvučne signale šišmiša sadrži i ostale zvučne signale iz okoliša. Zbog količine podataka koji se sakupe ovakvim načinom praćenja, ali i zasićenosti podataka šumom, ručni pregledi i analiza glasanja šišmiša su otežani, a u nekim slučajevima i nemogući.




Slika 1.2 Grafički prikaz spektrograma s tipičnim glasovima šišmiša. Od gornjeg prema donjem: FM, CF, FM-QCF, QCF-FM



*Slika 1.3 Razlika u anatomskej građi glave šišmiša koji proizvode glasove FM-QCF; oblika i šišmiša koji proizvode glasove CF oblika. A - (*Tadarida teniotis*); B - (*Rhinolophus ferrumequinum*)*

1.1 Ugroženost populacija šišmiša

Razlozi smanjenja populacija šišmiša na nekom području mogu biti različiti: gubitak staništa, utjecaj vjetroelektrana, epidemije zaraznih bolesti, stradavanja na cestama te napadi domaćih životinja. Dva najzastupljenija uzroka smrtnosti šišmiša u svijetu su zarazna bolest sindrom bijelog nosa (eng. *white-nose syndrome*) i stradavanje na vjetroelektranama (O'Shea i sur. 2016). Sindrom bijelog nosa uzrokuje gljivica *Pseudogymnoascus destructans* koja naseljava kožu šišmiša, a očituje se bijelim izrastom na njušci i oko njuške šišmiša. Bolest je prvi puta zabilježena 2006. godine na istočnoj obali SAD-a, a do rujna 2016, raširila se i do zapadne obale SAD-a (Blehert i sur. 2009). Ova bolest je trenutno lokalizirana samo na području Sjeverne Amerike te za sada nije zabilježen niti jedan slučaj zaraze drugdje na svijetu.



Slika 1.4 Kumulativni broj zabilježenih slučajeva višestrukih smrtnosti šišmiša u cijelom svijetu u odnosu na uzrok smrtnosti od 1790. do 2015. godine (O'Shea i sur. 2016)


Iako sindrom bijelog nosa potencijalno predstavlja veliku opasnost za šišmiše u cijelom svijetu, najčešći antropogeni uzrok smrtnosti šišmiša su vjetroeletreane (O'Shea i sur. 2016). Smrt šišmiša zbog vjetroeletreane može nastupiti na dva načina:

1. Smrt uzrokovana direktnim sudarom s lopaticom vjetroeletreane (a)
2. Smrt uzrokovana barotraumom (b i c)

Smrt uzrokovana barotraumom nastupa kada šišmiš uleti u područje niskog tlaka koje se stvara pri vrhu lopatice rotora vjetroatregata. Zbog razlike u tlaku i specifičnoj fiziologiji i anatomske građi šišmiša nastupaju oštećenja pluća i krvarenja u prsnoj i abdominalnoj šupljini šišmiša (Baerwald i sur. 2008). Kako su šišmiši prilagođeni za život u zraku razvili su niz specifičnih prilagodbi koje olakšavaju let poput, relativno velikih pluća i srca u odnosu na tijelo, visokog prijenosnog kapaciteta za kisik i jako tanke alveolarne barijere. Te prilagodbe ih čine posebno osjetljivim na promijene tlaka (Baerwald i sur. 2008).

Upravo zbog sve većeg ljudskog utjecaja na populacije šišmiša i njihove važnosti u okolišu potrebno je pratiti i bilježiti stanje njihovih populacija, posebno na lokacijama


poput vjetroparkova gdje su te populacije ugrožene. Stoga je od velike važnosti razviti i uhodati brze i pouzdane metode za prikupljanje i analizu podataka o aktivnosti šišmiša.



Slika 1.5 Nyctalus noctula - Smrt uzrokovana udarcem; (a) - otvoreni prijelom humerusa. Smrt uzrokovana barotraumom; (b) izljev krvi u prsnu šupljinu (c) unutarnje krvarenje u trbušnu šupljinu (Voigt i sur. 2015)

1.2 Zvuk

Zvuk je mehanički sinusoidni val koji se širi kroz nekakav medij u obliku longitudinalnog vala izmjene tlaka i/ili izmještaja čestica (Slika 1.6). S obzirom na ljudsko uho, zvukom se općenito smatraju mehanički valovi s frekvencijama od 16Hz do 20kHz. Zvukovi frekvencije niže od 16Hz nazivaju se **infrazvukom** a zvukovi frekvencije više od 20 kHz **ultrazvukom**. Kao i svaki val, zvuk ima svoja fizikalna svojstva: **valnu duljinu**, **frekvenciju**, **amplitudu**, intenzitet, brzinu i usmjerenje.



Slika 1.6 Primjer sinusoidnog vala s prikazanom amplitudom i valnom duljinom

Učestalost promjena tlaka i izmještaja čestica prilikom širenja zvučnog vala u vremenu naziva se frekvencijom zvuka. Frekvencija se izražava u mjernoj jedinici Hertz (Hz) gdje broj Hertza označava broj ponovljenih ciklusa vala u sekundi. U fizici se frekvencija izračunava kao omjer brzine širenja zvuka i valne duljine zvuka. Valna duljina je razmak između dva susjedna homologna djela valne krivulje. Primjerice, valna duljina može biti razmak između dva susjedna maksimuma krivulje (Slika 1.6). Brzina zvuka je brzina kojom se zvuk širi u nekom mediju (Jednadžba 1.1). Amplituda vala je vrijednost maksimuma ili minimuma koje val dostiže. Visina amplitude ovisi o količini energije koju val prenosi te ukazuje na intenzitet zvuka.

Jednadžba 1.1 Brzina i frekvencija zvuka u plinu

$$v = \sqrt{\frac{\chi * p}{\rho}}$$


$$f = \frac{v}{\lambda}$$

Gdje je:

- v - brzina zvuka u plinu
- ρ - gustoća plina
- χ - adijabatski koeficijent plina
- p - tlak plina
- f - frekvencija zvuka
- λ - valna duljina zvuka

Snimanje zvuka može biti obavljeno analogno ili digitalno. Analognim zapisom se pomoću mikrofonske dijafragme osjetljive na izmjene tlaka nastale zvukom bilježi mehanička ili magnetna reprezentacija zvučnih valova. Prilikom digitalnog snimanja zvuk se digitalizira. Zvuk je tada predstavljen kao niz brojeva koji korespondiraju vrijednostima amplitude u točno određenim vremenskim razmacima (Slika 1.7). Broj tih razmaka u jedinici vremena naziva se brzina ili učestalost uzorkovanja (eng. *sample rate*). Učestalost uzorkovanja izražava se također mjernom jedinicom za frekvenciju Hertz (Hz).

Za snimanje zvukova čujnih za čovjeka odnosno zvukova s frekvencijom 16Hz-20kHz dovoljno je snimanje s učestalosti uzorkovanja od 44.1kHz. Za snimanje ultrazvuka, koji je zvuk većih frekvencija potrebno je upotrijebiti uređaje sa sposobnošću digitaliziranja zvuka s većom učestalošću uzorkovanja. Kod snimanja eholokacijskih zvukova šišmiša preporučeno je snimanje s učestalošću uzorkovanja od 384kHz (Barataud 2015). Ovako visoka učestalost uzorkovanja omogućuje snimanje zvukova s frekvencijama i iznad 150kHz i trajanjem manjem od 1ms, pa je tako moguće snimati vrste s kratkim trajanjima glasanja (rod *Myotis*), ali i vrste koje se glasaju na vrlo visokim frekvencijama (rod *Rhinolophus*).



Slika 1.7 Primjer sinusoidnog vala koji je snimljen digitalno odnosno s određenom učestalošću uzorkovanja; Crvene točke označavaju zabilježenu informaciju a plava linija označava stvarni signal

1.2.1 Analiza zvuka

Zvuk se može grafički opisati s tri domene: domenom vremena, domenom frekvencije i domenom amplitude (intenziteta). Vrijeme je obično izraženo u sekundama i njega obično predstavlja horizontalna (os) grafova koji prikazuju ovisnosti amplitude ili frekvencije u vremenu. Kako bi nastali ovakvi grafički prikazi potrebno je koristiti različite računalne tehnike koje spadaju u Fourierovu analizu. Fourierova analiza je metoda definiranja periodične funkcije nekog oblika pomoću trigonometrijskih funkcija.

Sinusoida je matematička krivulja koja omogućuje opisivanje najjednostavnijih ponavljajućih kretanja u prirodi. Ponavljajuća karakteristika zvučnog vala odnosno izmjene tlaka zraka kojima se zvuk širi može se opisati sinusoidom. Činjenica da se bilo kakav zvuk može proizvesti kombinirajući neograničeni broj sinusoida čini temelj Fourierove analize. Ljudi kao i ostali kralježnjaci imaju pužnicu (lat. *cochlea*), organ koji analizira zvuk razdvajajući ga na njegove komponentne sinusoide, pri čemu je jedan kraj pužnice osjetljiv na niske frekvencije zvuka, a drugi na visoke frekvencije. Kada zvuk dođe do različitih dijelova pužnice stvaraju se različiti živčani impulsi koje interpretira mozak. Ovakvo razdvajanje frekvencija iz zvučnog signala matematički je moguće izvesti tehnikom Fourierove analize koja se naziva Fourierova transformacija (FT). Fourierova transformacija (FT) matematička je tehnika kojom se funkcija vremena (signal) razdvaja na frekvencije koje ga čine, što rezultira tzv. Fourierovom

reprezentacijom signala. Fourierova reprezentacija zvučnog signala prikazuje spektralnu kompoziciju analiziranog signala (Gerhard 2003). Snimke šišmiša se danas obično snimaju digitalno te se zbog toga prilikom transformacije snimljenog signala koristi diskretni oblik Fourierove transformacije (eng. *Discrete Fourier Transformation, DFT*). Ukoliko se spektralni sadržaj signala ne mijenja, DFT je prikladna tehnika za analizu signala. Međutim, ako je signal izmjenjiv u vremenu, primjerice glasanje šišmiša, samo primjenom DFT-a neće biti moguće razlikovati pojedini glas i promjene u signalu. Fourierova transformacija u kratkim vremenima (eng. *short-time fourier transformation, STFT*) omogućuje stvaranje prikaza frekvencije i intenziteta zvuka u odnosu na vrijeme. Ova transformacija pokušava ukloniti problem nedostatka vremenske domene DFT-a. Prilikom primjene STFT-a podaci signala se razdvajaju na manje uzastopne dijelove (prozore) na kojima se tada primjenjuje DFT. Rezultat STFT-a je vremenski ovisna reprezentacija zvuka koja pokazuje promjene harmonijskog spektra - spektrogram (Jednadžba 1.2 i Slika 1.8). STFT zbog karakteristika DFT-a u ovom obliku često rezultira diskontinuitetom signala. Kako bi se to spriječilo prilikom transformacije primjenjuje se neka **funkcija prozora** (eng. *windowing function*). Funkcije prozora su sinusne funkcije koje postupno skaliraju amplitudu signala pri svojim krajevima na nulu. Takve funkcije pomažu smanjivanjem greške na granicama pojedinog prozora STFT-a. U bioakustičnoj analizi glasova šišmiša najčešća funkcija prozora je tzv. Hanning funkcija (Barataud 2015) (Slika 1.9). Iako primjena funkcije prozora pomaže u uklanjanju greške granice prozora potrebno je prozore međusobno i preklopiti kako bi se greška što više smanjila. Ovaj parametar određuje se pomakom prozora Fourierove transformacije (eng. *hop size*).

Računalni postupci opisani u ovom poglavlju izvodili su se pomoću informatičkog okruženja za analizu snimaka ultrazvuka (Prilog 8.2).

Za izradu spektrograma snimke potrebno je:

1. Poznavati učestalost uzorkovanja snimke
2. Odrediti veličinu prozora STFT-a u jedinicama broja uzoraka (eng. *window size*)
3. Odrediti preklapanje pomoću parametra pomaka prozora u jedinici broja uzoraka (eng. *hop size*)
4. Odabrati funkciju prozora (eng. *windowing function*)


Jednadžba 1.2 STFT i izrada spektrograma iz rezultata STFT-a:

$$\text{STFT}\{x[n]\}(m, \omega) \equiv X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n - mR]e^{-j\omega n}$$


$$\omega, \text{spectrogram}(t, \omega) = |\text{STFT}(t, \omega)|^2$$

Gdje je:

- n - vrijeme
- m - dužina funkcije prozora u broju uzoraka
- $x[n]$ - ulazni signal u nekom vremenu
- $w[n]$ - funkcija prozora s određenom dužinom m
- R - veličina koraka između implementacija DTFT u broju uzoraka



*Slika 1.8 Spektrogram glasanja šišmiša *Pipistrellus kuhlii*, horizontalna (x) os označava vrijeme u milisekundama; vertikalna (y) os označava frekvenciju u kHz; intenzitet obojenja polja označava intenzitet, odnosno količinu energije u određenoj frekvenciji i vremenu; parametri snimke su: veličina fft prozora = 1024, duljina fft pomaka=64, funkcija prozora=Hanning*



Slika 1.9 Grafički prikaz Hanning (Hann) funkcije prozora kojim se sprečava diskontinuitet signala tijekom STFT-a. Lijeva slika prikazuje izgled funkcije gdje vertikalna os označava amplitudu, a horizontalna broj uzoraka na kojima se primjenjuje Hanning funkcija. Desna slika prikazuje frekvencijski odziv funkcije (vertikalna os prikazuje magnitudu na logaritamskoj skali, a horizontalna os broj ciklusa po uzorku odnosno normaliziranu frekvenciju)

1.3 Analiza velikog skupa podataka - podatkovno rudarenje

Skupovi podataka koji su toliko veliki ili kompleksni da se tradicionalnim tehnikama obrade podataka ne mogu obraditi u prihvatljivom vremenu nazivaju se **velikim skupovima podataka** (eng. **big data**). Veliki skupovi podataka nastaju svakodnevno u širokom spektru ljudskog djelovanja. Primjerice, u znanosti veliki skupovi podataka nastaju kao rezultat kompleksnih istraživanja, automatiziranih mjerenja ili prilikom matematičkog opisivanja (modeliranja) prirodnih pojava. Veliki i kompleksni skupovi podataka vrlo su česti u meteorologiji, eksperimentalnoj fizici, biologiji, znanosti o okolišu itd. Kako bi se veliki skupovi podataka mogli uspješno analizirati potrebno je primijeniti specifične računalne metode za njihovu obradu i analizu. Takve metode moraju imati sposobnost prepoznavanja specifičnih uzoraka iz velikog skupa. Grana računalne znanosti koja se bavi prepoznavanjem takvih uzoraka u velikim skupovima podataka naziva se **podatkovno rudarenje** (eng. **data mining**). Podatkovno rudarenje interdisciplinarna je grana računalstva koje objedinjuje umjetnu inteligenciju, strojno učenje, statistiku i sustave za pohranu i manipulaciju podacima. **Strojno učenje** (eng. **machine learning**) široki je skup metoda za stvaranje sustava odnosno

modela koji uče iz određenog skupa podataka u svrhu klasifikacije nepoznatih podataka te obuhvaća različite pristupe toj problematici. Samo neki od pristupa su upotreba umjetnih neuronskih mreža, genetičkih algoritama i grupiranja (eng. *clustering*) podataka. Razvoj i pad cijena grafičkih jedinica opće namjene (eng. *general purpose graphical processing units*, GPGPU) omogućio je nagli razvoj potpuno novih metoda strojnog učenja. Ove metode omogućavaju stvaranje algoritama za modeliranje visokih razina apstraktnosti podataka koristeći višestruke razine odlučivanja i predviđanja (Deng 2014). Modeli temeljeni na visokoj razini apstrakcije spadaju u dio strojnog učenja koji se naziva **duboko učenje** (eng. **deep learning**). Ovisno o vrsti podataka na kojima se izvodi podatkovno rudarenje u mnogim slučajevima je potrebno koristiti tehnike prepoznavanja uzoraka i iz drugih grana računalstva poput računalnog vida.

Svaki sustav temeljen na strojnom učenju prilikom izrade prolazi kroz tri glavna koraka:

1. Prethodna obrada (*preprocessing*) ili priprema podataka
2. Izrada i treniranje modela
3. Evaluacija modela

2 Ciljevi istraživanja

Ciljevi ovog istraživanja su:

1. Utvrditi osobine šuma u audio snimkama i mogućnost izolacije snimke glasanja šišmiša od ostatka snimki
2. Utvrditi osobine glasanja šišmiša odnosno karakterizirati glasanje šišmiša u smislu frekvencije i pojavnosti kao posljedicu specifičnih frekvencijsko-vremenskih struktura pomoći SURF deskriptora.
3. Utvrditi preciznost klasifikacije modela za izdvajanje audio snimki glasanja šišmiša prilikom podatkovnog rudarenja
4. Utvrditi mogućnosti primjene modela temeljenih na neuronskim mrežama za prepoznavanje snimki glasanja šišmiša u velikim skupovima podataka

3 Materijali i metode

U sklopu ovog rada izrađena su dva modela za klasifikaciju audio snimki temeljena na neuronskim mrežama. Prije izrade modela bilo je potrebno razviti programsko okruženje za manipulaciju i osnovnu transformaciju zvučnih zapisa (prilog 2). Svaki od modela izrađen je u 3 glavna koraka. U prvom koraku izvelo se predprocesiranje podataka u svrhu pripreme za klasifikaciju. U drugom koraku izrađeni su i trenirani modeli za polu-nadzirano učenje (eng. *semisupervised learning*) kojima su ulazni podaci bili podaci dobiveni u prvom koraku. Treći korak obuhvaćao je validaciju modela, odnosno testiranje sustava na neovisnim podacima. Ovisno o tipu modela postojale su razlike u načinu izvođenja pojedinog koraka.

3.1 Podaci

Podatke o šišmišima koji su korišteni u svrhu ovoga istraživanja ustupila je tvrtka *Geonatura d.o.o. za stručne poslove zaštite prirode*. Podaci su dio velikog skupa podataka prikupljenog tijekom istraživanja utjecaja VE Danilo na populacije šišmiša.

VE Danilo je najveća vjetroelektrana u Hrvatskoj. Sastoji se od 19 vjetroagregata (ENERCON E-82) postavljenih u dva niza. Svaki vjetroagregat na VE Danilo visok je 78 m do gondole (glava, generator ili *hub*) i s promjerom rotora od 82 m, odnosno visina agregata sa lopaticama je oko 120 m (Slika 3.1) (Enercon 2016). Jedan ovakav agregat proizvodi 2 MW električne energije.

Vjetroelektrana Danilo puštena je u pogon 2014. godine. Kako bi se utvrdio njezin utjecaj na šišmiše propisano je praćenje (monitoring) populacija šišmiša u okolici vjetroelektrane. Praćenje šišmiša na vjetroelektranama obično obuhvaća sljedeće:


- **Kontinuirano praćenje šišmiša (od sumraka do zore) ultrazvučnim detektorima**
- Utvrđivanje pravaca leta i migratornih puteva
- Utvrđivanje obrazaca ponašanja za svaku uočenu vrstu
- Utvrđivanje odnosa lokalnih populacija šišmiša iz većih kolonija prema vjetroelektrani
- Praćenje smrtnost šišmiša oko svakog vjetrogeneratora
- Sakupljanje mrtvih životinja i utvrđivanje vrste, spola i starosti

Utvrđivanje da li neki od generatora uzrokuje neprihvatljivu razinu smrtnosti u populacijama šišmiša, uzevši u obzir broj životinja, status i ugroženost. (Rnjak i sur. 2016)

Najveći dio podataka prikupljen je tijekom kontinuiranog praćenja šišmiša stacionarnim ultrazvučnim detektorima Song Meter SM2BAT+. Dio podataka prikupljen tijekom transektnog praćenja snimljen je prijenosnim ultrazvučnim detektorom Elekon Batlogger (Slika 3.2). Podaci su spremljeni u obliku .wav datoteka (eng. *waveform audio file format*) u trajanju do maksimalno 5 sekundi s učestalošću uzorkovanja od 384kHz. Ovaj diplomski rad temeljen je na dva skupa ultrazvučnih snimaka. Manji skup od 495 snimaka služio je za treniranje modela dok je veći skup, od 4051 snimke, služio u validaciji modela.

Skup za treniranje modela kompilirani je skup podataka nastao prilikom prikupljanja snimki šišmiša kontinuiranim (stacionarni betdetektori) i transektnim (prijenosni betdetektori) praćenjem šišmiša i obuhvaćao je sve fonetske tipove glasanja šišmiša i mnogobrojne šumove koje je bilo moguće snimiti u blizini vjetroatagregata. Za potrebe treniranja modela ovi podaci su bili podijeljeni na snimke koje sadrže glasove šišmiša i snimke koje ne sadrže glasove šišmiša. Slike 4.3 – 4.6 prikazuju primjere odsječaka snimaka šišmiša iz skupa za treniranje modela. S obzirom da cilj ovog rada nije bila identifikacija pojedine vrste šišmiša na temelju snimki glasanja (što će biti predmetom budućih istraživanja na istom uzorku) već samo prisutnost njihovih glasova na pojedinoj snimci (s ciljem što preciznijeg odvajanja odsječaka snimke s glasanjem šišmiša od odsječaka bez glasanja, što je u praksi zaštite šišmiša i najvažniji podatak, s obzirom da su u Europi svi šišmiši strogo zaštićene vrste), nije u istraživanju bilo posebno važno identificirati vrste šišmiša u audio uzorku. Unatoč tome, sve analizirane snimke su označene prema odgovarajućoj vrsti, rodu ili fonetskoj skupini kojoj snimljeni šišmiši pripadaju.

Skup za validaciju modela prikupljenih tijekom kontinuiranog snimanja šišmiša na mjernom stupu u blizini VE Danilo u srpnju 2015. godine. Snimke koje sadrže šišmiše su bile poznate za svrhu validacije dok vrste i fonetski tipovi šišmiša na istima prije validacije modela nisu bili poznati.




Slika 3.1 Shematski prikaz dimenzija jednog vjetroagregata na VE Danilo




Slika 3.2 Ultrazvučni detektori korišteni za prikupljanje podataka o šišmišima na VE Danilo. A - Song Meter SM2BAT+ za kontinuirano praćenje i B - Elekon Batlogger za transektno praćenje, (Foto D. Rnjak)




Slika 3.3 A – postavljeni ultrazvučni detektor na gondoli vjetroagregata (Foto: G. Rnjak); B – postavljanje ultrazvučnog detektora na mjerni stup u blizini VE Danilo (Foto: V. Zrnčić)




Slika 3.4 Odsječak snimke šišmiša vrste *Barbastella barbastellus*




Slika 3.5 Odsječak snimke vrste *Hypsugo savii*



Slika 3.6 Odsječak snimke šišmiša, pripadnika roda Myotis




Slika 3.7 Odsječak snimke vrste Tadarida teniotis



Slika 3.8 Specifični oblici glasanja nekih od šišmiša iz skupa podataka za učenje. Spektrogrami od gornjeg prema dolje sadrže glasanja rodova: Myotis (FM), Rhinolophus (CF), Hypsugo (FM-QCF) i Barbastella (QCF-FM)

3.2 Prethodna obrada podataka


Snimke su se iz .wav formata transformirale u spektrogram korištenjem STFT algoritma pomoću okruženja za manipulaciju podacima (Prilog 8.2). Veličina prozora Fourierove transformacije iznosila je 512 uzoraka, dok je pomak prozora bio zadan sa 64 uzorka odnosno preklapanje uzastopnih prozora Fourierove transformacije iznosilo je 87,5%. Za funkciju prozora, prema literaturi, odabrana je Hanning funkcija (Barataud 2015). Ovakva transformacija snimke od 5 s koja je snimljena učestalošću uzorkovanja od 384kHz rezultira s dvodimenzionalnim spektrogramom rezolucije 256x29992 (7.677.952) uzorka. Svaki uzorak u horizontalnoj rezoluciji odgovara 0,168 milisekundi snimljenog vremena dok svaki uzorak spektrograma u vertikalnoj osi odgovara koraku frekvencije od 750 Hz. Ovakvi spektrogrami snimaka sadrže znatno veću količinu podataka u dimenziji vremena što ih čini gotovo nemogućim za pregled ljudskim okom bez računalne pomoći (Slika 3.9).



Slika 3.9 Spektrogram snimke glasanja šišmiša roda Myotis, FT veličina prozora: 512; pomak prozora: 64; učestalost uzorkovanja: 312,5 kHz; gornji dio slike predstavlja spektrogram cijele snimke u trajanju od 2.7 sekunde; donji dio je uvećani početak snimke do približno 330-te milisekunde gdje se jasno vide FM glasovi prisutni u spektrogramu

Ipak spektrogrami ovih rezolucija sadrže maksimalnu količinu informacija o zvukovima za brzu računalnu obradu. Prilikom preliminarnih analiza upravo se velika vremenska rezolucija u odnosu na frekvencijsku rezolucija pokazala ključnom za izdvajanje šišmiša od pozadinskih zvukova. Razlog tome su šišmiši koji ispuštaju FM glasove vrlo kratkih trajanja posebice šišmiši iz rodova *Myotis* i *Plecotus*. Ukoliko vremenska rezolucija u tim slučajevima nije dovoljno velika specifični oblik ovih zvukova nije

dovoljno dobro prezentiran u prostoru spektrograma. Parametar koji utječe na rezoluciju spektrograma u dimenziji vremena je postotak preklapanja pojedinog prozora Fourierove transformacije odnosno pomak prozora (Slika 3.10)




*Slika 3.10 Na slici je prikazano 330 milisekundi snimke glasanja šišmiša iz roda *Myotis* u obliku dva spektrograma proizvedena iz iste snimke; oba spektrograma izrađena STFT-om s parametrom veličine prozora od 512 uzoraka i funkcijom prozora Hanning. Jedina razlika između spektrograma je pomak prozora u vremenu gdje u gornjem spektrogramu pomak iznosi čak 489 uzoraka odnosno preklapanje uzastopnih prozora iznosi samo 4,5% a u donjem spektrogramu korišten je pomak od 64 uzoraka odnosno preklapanje uzastopnih prozora od 85,7%.*

Za potrebe oba modela izdvojile su se karakteristične značajke snimaka primjenom algoritma za izdvajanje deskriptora koji se nazivaju “ubrzane robusne značajke” (eng. *speeded up robust features*, **SURF**).

SURF značajke posebni su deskriptori rasterskih podataka koji izdvajaju posebna područja interesa određenog rastera na temelju razlika u lokalnim promjenama kontrasta polja primjenom Gaussovog filtera (Bay i sur. 2006.; Ess i sur. 2008.; Funayama i sur. 2009). U ovom slučaju tu razliku čini razlika između bliskih polja koja opisuju vrijeme i frekvenciju spektrograma. Rezultat primjene algoritma za pronalazak SURF značajki su vektori koji opisuju interesna područja spektrograma duljine od 128 broja. Izdvajanje SURF značajki izvedeno je na dva načina. U prvom načinu, algoritam za izdvajanje SURF značajki izveo se preko spektrograma cjelokupne snimke. U drugom načinu, prije primjene algoritma za izdvajanje SURF značajki primijenio se algoritam za detekciju zvučnih događaja. Ovaj algoritam izdvaja vremenske odsječke pojedine snimke ukoliko detektira događaje u određenim vremenima. Nakon toga se na spektrogram svakog odsječka primijenio algoritam za detekciju SURF značajki identičan onome u prvom načinu. I u prvom i drugom slučaju nastaje velika količina SURF vektora koji matematički opisuju značajke spektralnog polja snimaka. U drugom slučaju SURF značajke se preciznije, određuju jer algoritam ne uzima u obzir cjelokupnu snimku već samo manji vremenski odsječak koji predstavlja zvučni događaj. Algoritam za detekciju i izdvajanje događaja je napisan u svrhu izdvajanja mogućeg glasa šišmiša iz spektrograma za potrebe izrade ovog diplomskog rada, a temelji se na detekciji događaja u energetske i frekvencijske reprezentaciji snimke i automatskom čišćenju pozadinskog i sustavnog šuma (Prilog 8.3.1 Šumovi).

S obzirom da su se specifične značajke snimki izdvajale na dva različita načina izrađena su dva modela za klasifikaciju snimki:

1. Model 1 - Model za binarnu klasifikaciju pomoći SURF značajki sakupljenih na temelju cijele snimke
2. Model 2 - Model za binarnu klasifikaciju pomoći SURF značajki sakupljenih na temelju zvučnog događaja



*Slika 3.11 Primjer prepoznavanja područja interesa na spektrogramu glasanja šišmiša *Pipistrellus khulii* pomoću jednosmjernih SURF deskriptora, Gornji spektrogram prikazuje jedan FM-QCF glas šišmiša *Pipistrellus khulii*. Donji spektrogram prikazuje isti glas prikazan zajedno sa poljima koje je algoritam za izdvajanje SURF značajki izdvojio. Svaki krug označava polja koja su numerički opisana u jednoj SURF značajki ovog odsječka.*

3.3 Izrada i treniranje modela za klasifikaciju pomoći SURF značajki

Oba izrađena modela za binarnu klasifikaciju pomoći SURF značajki spadaju u modele za polunadzirano učenje. Modeli kojima su ulazni podaci proizašli iz izdvajanja SURF značajki spadaju u skupinu modela koji se nazivaju **modeli „vreće riječi“** (eng. *bag of words models*). Ovakvi modeli koriste se u izradi sustava za prepoznavanje govora, ali i u sustavima za računalni vid (Sivic i Zisserman 2009), te klasificiraju značenje specifičnog redoslijeda, vrste i razmještaja skupine „riječi“ u određeno značenje. Termin „riječi“ ovdje ne podrazumijevaju nužno tekstualne podatke (iako mogu biti i takvi) nego to također mogu biti numerički ili grafički podaci. Za izradu ovakvog modela potrebno je imati rječnik „riječi“ (kao specifičnih skupina podataka kojima model raspolaže).

Kako bi se odredile „riječi“ za modele pretpostavilo se da će SURF značajke prikupljene na području glasova šišmiša biti međusobno više ili manje slične. To se odnosi i na značajke sakupljene na poljima koje označavaju šum. Ta sličnost je bila nepoznata, odnosno broj grupa značajki („riječi“) koje su međusobno slične je bio nepoznat. Kako bi se ustanovile grupe sličnih značajki primijenio se algoritam za grupiranje podataka (eng. *data clustering*) nazvan „k-means“ grupiranje (eng. *k-means clustering*). Ovaj dio obrade podataka čini modele nenadziranim (eng. *unsupervised*), jer izgled „riječi“ odnosno klase kojima pojedina SURF značajka pripada nije unaprijed poznat (klase su unaprijed nepoznate, pa se određuju bez usporedbe s unaprijed zadanim uzorcima kao reprezentantima unaprijed zadanih klasa, u kojem bi se slučaju radilo o nadziranoj klasifikaciji).

Za skup podataka $(x_1, x_2, x_3, \dots, x_n)$, gdje je svaki podatak n -dimenzionalni vektor i k -means algoritam dijeli podatke na $k (\leq n)$ broj skupova $S = (S_1, S_2, S_3, \dots, S_k)$, k -means grupiranje opisano je sljedećom jednačbom 4.

Jednadžba 3.1 k-means klasteriranje

$$\arg \min \sum_{i=1}^k \sum_{x \in S_i} ||x - \mu_i||^2$$

Gdje je:


- k - Broj grupa ili klastera
- S_i - Pojedina grupa ili klaster
- μ_i - Prosjek točaka u S_i
- $||x - \mu_i||^2$ - Euklidska udaljenost između x_i i μ_i

U ovom koraku broj grupa se nije odredio on ovisi o preciznosti klasifikacije završnog modela odnosno on se određuje u procesu optimizacije arhitekture neuronske mreže. Svaka određena grupa dobivena prilikom grupiranja predstavlja jednu „riječ“.

Za potrebe ovih modela postavljena je neuronska mreža s ulaznim slojem čiji broj neurona (ulaznih varijabli) odgovara broju „riječi“ u rječniku. Odnosno ulazne varijable neuronske mreže su bili brojevi „riječi“ zastupljeni u snimci ili odsječku snimke. Vanjski sloj sadržavao je dva neurona što odgovara potrebama klasifikacije. Neuronska mreža sadržavala je jedan skriveni sloj koji je odgovarao prosjeku broja neurona ulaznog i izlaznog sloja (Jednadžba 3.3 Slika 3.12). Aktivacijska funkcija za potrebe oba modela bila je ispravljajuća linearna funkcija (*eng. rectifier*). Odnosno svaka jedinica neuronske mreže bila je ujedno i ispravljajuća linearna jedinica (ReLU).

Jednadžba 3.2 Ispravljajuća funkcija (eng. rectifier)

$$f(x) = \max(0, x)$$



Slika 3.12 Shematski prikaz arhitekture umjetne neuronske mreže s jednim skrivenim slojem. Stvarne korištene arhitekture neuronskih mreža nakon optimizacije imale su 55 neurona u ulaznom i 28 u skrivenom sloju za Model 1, te 332 neurona u ulaznom i 167 u skrivenom sloju, dok je u izlaznom sloju u oba slučaja bilo dva neurona koji su reprezentirali dva moguća računski rezultata (1 ili 0; binarni odgovor na pitanje da li konkretni audio odsječak predstavlja glasanje šišmiša ili ne).

Jednadžba 3.3 Jednadžba na temelju koje je određena veličina skrivenog sloja neuronske mreže

$$N_h = \frac{N_i + N_o}{2}$$


Gdje je:

- N_h - broj skrivenih neurona
- N_i - broj ulaznih neurona
- N_o - broj izlaznih neurona

Kako bi se odredila optimalna arhitektura neuronske mreže izvedena je diskretna optimizacija modela. Na temelju rezultata optimizacije simuliran je logistički rast preciznosti modela (Slika 3.13). Kao korak koji označava optimalnu arhitekturu modela za binarnu klasifikaciju odabran je korak u kojoj simulirani rast preciznosti prelazi 99,95%.

Optimalna arhitektura Modela 1 sadržavala je 55 neurona u ulaznom sloju i 28 neurona u skrivenom sloju s ostvarenom i ujedno maksimalnom preciznosti modela na testiranom skupu od 107 snimaka od 99.95069%.

Optimalnu arhitekturu Modela 2 činilo je 332 neurona u ulaznom sloju i 167 neurona u skrivenom sloju pri tome je postignuta preciznost od čak 99,99046%. Trening oba modela pri svakom koraku optimizacije odvijao se u 2.000 ponavljanja.



Slika 3.13 Grafički prikaz primjera optimizacije arhitekture modela neuronske mreže s jednim skrivenim slojem za binarnu klasifikaciju podataka

3.4 Validacija modela

Prije same validacije u skupu podataka za validaciju ručnim pregledom podataka ustanovljeno je 584 snimke koje sadržavaju glasove šišmiša. Rezultat ručnog pregleda prilikom validacije smatran je točnim. Nakon obrade podataka izrađenim modelima za potrebe analize točnosti izrađene su matrice zabune (eng. *confusion matrices*) (Tablica 3.1) i izvela se usporedba dva modela. Uz izvedenu validaciju izvela se i usporedba s rezultatima dobivenih pomoću dva komercijalno dostupna programa za izdvajanje i analizu snimki šišmiša: *Kaleidoscope* i *Sonobat*.

Kaleidoscope je program za automatsko procesiranje i obradu snimljenih podataka koji omogućuje meko filtriranje podataka na temelju frekvencijskih raspona i svojih unutarnjih algoritama. *Kaleidoscope* je također i službeni program za obradu snimaka snimljenih ultrazvučnim detektorom (Song Meter SM2BAT+) korištenog prilikom sakupljanja ovih podataka. *Sonobat* je program za identifikaciju šišmiša koji producira interaktivni STFT spektrogram te pomaže u ručnom određivanju prisutnosti šišmiša na snimkama.

Tablica 3.1 Primjer matrice zabune za binarnu klasifikaciju. Prvi red sadrži oznake za klase koje su klasificirane modelom dok prvi stupac sadrži oznake stvarnih klasa (0 - oznaka za snimke bez glasova šišmiša, 1 - oznaka za snimke sa glasovima šišmiša). Stoga brojevi u dijagonali od gornjeg lijevog kuta do donjeg desnog kuta uvijek sadrže broj podataka koji su se pravilno klasificirali u određene klase. U ovom slučaju 15 snimaka koje ne sadrže šišmiše i 18 snimaka koje sadrže šišmiše pravilno su se klasificirale dok su se 3 snimke koje ne sadrže šišmiše klasificirale kao da sadrže i 4 snimke koje sadrže šišmiše su se klasificirale kao da ne sadrže

	0	1
0	15	3
1	4	18

4 Rezultati

4.1 Model 1

Model 1 pravilno je klasificirao 2680 snimaka odnosno 66,16%. Od 582 prisutnih snimaka s glasovima šišmiša pravilno je klasificirano 519 snimaka, 89.18 %. 1308 snimaka na kojima nije bilo prisutno glasova šišmiša klasificirale su se kao snimke šišmiša, dok su 63 snimke šišmiša klasificirane kao snimke bez glasanja šišmiša.

Tablica 4.1 Matrica zabune Modela 1. Zelenom bojom označeni su podaci koji su pravilno klasificirani a crvenom podaci koji nisu pravilno klasificirani.

	0	1
0	2161	1308
1	63	519

4.2 Model 2

Model 2 pravilno je klasificirao 3688 snimki odnosno 91,04%. Od 584 prisutnih snimaka s glasovima šišmiša pravilno je klasificirao 487 snimke ili 83,68%. Tek 268 snimaka na kojima nije bilo prisutno glasova šišmiša klasificirale su se kao snimke koje sadrže šišmiše dok se 95 snimka šišmiša koje su sadržavale glasove šišmiša klasificiralo kao snimke koje ne sadrže glasove šišmiša.

Tablica 4.2 Matrica zabune Modela 2. Zelenom bojom označeni su podaci koji su pravilno klasificirani a crvenom podaci koji nisu pravilno klasificirani.

	0	1
0	3201	268
1	95	487

4.3 Usporedba komercijalnih rješenja i izrađenih modela


Program Sonobat pokazao se kao najlošije rješenje za izdvajanje snimaka sa samo 17,35% pravilno klasificiranih snimki. Program Kaleidoscope (Wildlife acoustics) pravilno je klasificirao 59,15% snimki. Usporedno s Kaleidoscope-om Model 1 pokazao je sličnu izvedbu s pravilnom klasifikacijom 66,15% snimki šišmiša. Na posljetku Model 2 s 90,39% pravilno klasificiranih snimki dao je najbolje rezultate. Iako Model 2 dao je najbolje rezultate prilikom filtriranja podataka on pokazuje i najmanji postotak pravilne detekcije šišmiša od 83,68% odnosno greška detekcije šišmiša iznosila je 16,32%. Važna mjera pouzdanosti modela je i količina lažne detekcije snimaka odnosno količina snimaka na kojima nisu bili prisutni glasovi šišmiša, a koje je korišteni sustav detektirao kao snimke koje sadrže glasove šišmiša (eng. *false positive error*). Ova mjera se izrazila kao postotak snimaka rezultata koji ukazuju na snimke koje sadrže šišmiše, a zapravo ih ne sadrže (Tablica 4.4 i Slika 4.1).

Tablica 4.3 Matrice zabune nastale prilikom obrade istog skupa podataka programima Kaleidoscope, Sonobat i modelima 1 i 2.

		0	1
Sonobat	0	131	3338
	1	10	572
		0	1
Kaleidoscope	0	1867	1602
	1	53	529
		0	1
Model 1	0	2161	1308
	1	63	519
		0	1
Model 2	0	3201	268
	1	96	487

Tablica 4.4


	UKUPNA PRECIZNOST	PRECIZNOST DETEKCIJE ŠIŠMIŠA	LAŽNO POZITIVNA KLASIFIKACIJA
SONOBAT	17,35%	98,28%	85,37%
KALEIDOSCOPE	59,15%	90,89%	75,18%
MODEL 1	66,16%	89,18%	71,59%
MODEL 2	90,40%	83,68%	35,50%




Slika 4.1 Usporedba preciznosti detekcije šišmiša izrađenih modela i dostupnih komercijalnih rješenja

4.4 Analiza pogreške klasifikacije



Pregledom rezultata izrađenih modela ustanovljeno je da su 49 snimki šišmiša oba modela pogrešno klasificirala. U svrhu dodatne provjere Modela 1 i Modela 2 provedena je gruba vizualizacija tih snimaka što je rezultiralo sa 49 spektrograma. Pregledom ovih spektrograma ustanovljeno je da 23 snimke sadrže šumove koji maskiraju glasove šišmiša na dva specifična načina. U prvom slučaju glas šišmiša se frekvencijski i vremenski, većom ili manjom mjerom poklapa sa zvukovima šuma (često zvuci insekata) (Slika 4.2). To se najčešće događa prilikom detekcije vrsta s glasovima nižih frekvencija poput onih od vrste *Tadarida teniotis*. U drugom slučaju glas šišmiša je jednostavno preslab da bi ga bilo moguće razlučiti u snimci (Slika 4.3) što se najčešće događa prilikom detekcije šišmiša FM glasa koje su bile na većoj udaljenosti od bat detektora poput rodova *Myotis* i *Plecotus*. Od 49 snimaka koja oba modela prema rezultatima ručnog pregleda nisu dobro klasificirala, njih 26 zapravo nije sadržavala glasove šišmiša, što se pripisalo greški ručnog pregleda. Model 1 nepravilno je klasificirao još 14 snimki glasova šišmiša. Pregledom spektrograma tih snimki ustanovljeno je da su samo dva spektrograma bez ikakvih glasova šišmiša dok su ostale greške odgovarale već opisanim tipovima greške. Model 2 uz 49 već pregledanih snimki šišmiša nepravilno je klasificirao još 47 snimaka. Spektrogrami ovog modela pokazali su da je još 12 snimaka šišmiša ručnim pregledom nepravilno klasificirano. Iz rezultata modela 2 također su se vizualizirale i 269 snimke koje je model klasificirao kao snimke sa glasovima šišmiša, a prilikom ručnog pregleda su klasificirane kao snimke bez glasova šišmiša. Prilikom pregleda ovih spektrograma ustanovljeno je 10 snimaka koje ipak sadržavaju glasove šišmiša i koje je model zapravo uspješno detektirao. Stoga od prvotno određenih 582 snimke šišmiša u skupu podataka za validaciju zapravo je bilo barem 554 snimki šišmiša odnosno preciznost prilikom ručnog pregleda iznosila je **95,19%**. Na temelju ovih podataka može se izvesti i korekcija rezultata validacije izrađenih modela (Tablica 4.5, Tablica 4.6 i Slika 4.6).




Slika 4.2 Primjer spektrograma sa zvucima koji maskiraju glas šišmiša u vremenu i frekvenciji. Plave strelice pokazuju na glasove šišmiša koji su jasno vidljivi ali zbog zvukova koji se javljaju u sličnim frekvencijskim i vremenskim područjima nisu vidljivi



Slika 4.3 Primjer spektrograma sa vrlo slabim FM glasovima šišmiša. Plave strelice pokazuju na vrlo slabe signale šišmiša koji nisu detektirani.




Slika 4.4 Spektrogrami snimaka na kojima je ručnim pregledom određena prisutnost glasova šišmiša a modeli 1 i 2 te snimke određuju pravilno



Slika 4.5 Spektrogram snimke koja je ručnom klasifikacijom određena kao snimka koja sadrži glasove šišmiša a modeli 1 i 2 klasificiraju kao snimku bez glasova šišmiša

Tablica 4.5 Matrice zabune te postoci ukupne pravilne klasifikacije (U) i pravilne detekcije šišmiša(Š) nakon korekcije za Model 1 i Model 2

		0	1			0	1
Model 1	0	2189	1308	Model 2	0	3239	258
	1	35	519		1	57	497



Slika 4.6 Grafički prikaz ukupne preciznosti i detekcije šišmiša nakon korekcije

Tablica 4.6

	UKUPNA PRECIZNOST	PRECIZNOST DETEKCIJE ŠIŠMIŠA	POSTOTAK LAŽNIH POZITIVNIH SNIMKI
MODEL 1	66,85%	92,22%	71,59%
MODEL 2	93,68%	89,71%	34,17%

5 Rasprava

Način prikupljanja i analiza podataka o rasprostranjenosti, veličini populacija i ponašanju šišmiša ovisi o dostupnosti i kvaliteti podataka dobivenih snimanjem ultrazvučnim detektorima (Bernard i Fenton 2002; Fenton 1997; Barataud 2015). Kvaliteta podataka dobivenih snimanjem ultrazvučnim detektorima ovisi o puno okolišnih čimbenika kao što su: vrsta terena, vrsta i osjetljivost ultrazvučnog detektora, vremenske prilike, udaljenost od prometnica, glasanje drugih životinja, otvorenost staništa, jeka, prisutnost drugih antropogenih izvora zvuka, frekvencije i trajanje glasova šišmiša itd. Svi ti čimbenici u većoj ili manjoj mjeri ograničavaju mogućnosti kvalitetnog prikupljanja podataka na željenim mjestima, što ponekad gotovo onemogućuje kvalitetno praćenje i pouzdano kvantificiranje antropogenih utjecaja na populacije šišmiša. Vrlo često pregled i kvantifikacija podataka postaje vremenski i fizički prezahtjevna te se zbog toga u takvim slučajevima odustaje od kontinuiranog praćenja stanja populacija šišmiša. Takva situacija prilikom praćenja šišmiša opisana je posebno kod praćenja šišmiša u blizini vjetroelektrana (Hayes 2013).

Sustavi temeljeni na strojnom učenju do sada su se koristili samo za probleme identifikacije vrste šišmiša. Pri tome su se koristile razne metode poput statističke analize (Russo i Jones 2002; Papadatou i sur. 2008), statističkog učenja (Stathopoulos i sur. 2014; Lucas 2000) i umjetnih neuronskih mreža (Jennings, Parsons, i Pocock 2008; Mirzaei i sur. 2011; Redgwell i sur. 2009; Walters i sur. 2012; Parsons i Jones 2000). Ulazni podaci sakupljeni za identifikaciju vrsta šišmiša su obično ručno mjereni parametri glasova iz spektrograma pomoću različitih softverskih rješenja. Samo izdvajanje snimaka koje sadrže glasove šišmiša iz velikog skupa podataka pomoću sustava temeljenih na strojnom učenju bez fokusa na identifikaciju nije pronađeno u literaturi.

Tvrtka Geonatura d.o.o. je tijekom istraživanja utjecaja VE Danilo na razinu aktivnosti populacija šišmiša u ovisnosti o mikroklimatskim uvjetima 2015. godine izvela kontinuirano praćenje populacija šišmiša pomoću 7 ultrazvučnih detektora. U tu svrhu sakupljeno je 1.826.664 snimaka mogućih glasova šišmiša u trajanju do maksimalno 5 sekundi (Rnjak i sur. 2016). Ručni pregled ove količine podataka trajao bi jako dugo te je bilo potrebno razviti rješenje koje će s minimalnom greškom izdvojiti snimke šišmiša iz cjelokupnog skupa. Iz te potrebe razvili smo sustav Komori koji se tada i

koristio u analizi te je uvelike potpomogao i ubrzao analizu snimaka. Ovaj diplomski rad donosi opis principa rada ovog sustava (Model 2).

Izrađeni modeli ne pronalaze glasove šišmiša na temelju specifičnih parametara pojedinih glasova šišmiša kao na primjer, statistički ključ opisan u knjizi *Acoustical Ecology of European Bats* (Barataud 2015) ili sustava za automatiziranu identifikaciju opisanih u literaturi (Jennings i sur. 2008; Walters i sur. 2012; Parsons i Jones 2000; Russo i Jones 2002; Lucas 2000; Papadatou i sur. 2008), već oponašaju kognitivne sposobnosti samih stručnjaka za prepoznavanje zvukova iz snimki pomoću matematičkih transformacija podataka te naprednih računalnih metoda izdvajanja lokalnih značajki koje proizlaze iz računalnog vida (SURF). Modeli temeljeni na principu rada modela „vreće riječi“ (eng. *bag of words model*) i izdvajajući SURF deskriptora iz spektrograma omogućili su uspješnu binarnu klasifikaciju prilikom podatkovnog rudarenja. Međutim, oni nisu dovoljno dobri za automatsku identifikaciju šišmiša odnosno klasifikaciju na više klasa. Glavni razlog tome leži u neovisnosti i lokalnom karakteru SURF deskriptora. Naime, SURF deskriptori ne sadržavaju podatke o frekvenciji i trajanju dijela spektrograma već samo lokalne promjene vrijednosti polja, odnosno oblike i obrise zvuka kojeg opisuju. Svi modeli temeljeni na neuronskim mrežama uvelike ovise o ulaznim podacima na kojima su trenirani. Za kvalitetno treniranje ovih modela potrebno je imati kvalitetno izdvojene i klasificirane podatke. Izrađeni modeli su trenirani podacima koji su prikupljeni u neposrednoj blizini vjetroelektrane VE Danilo. Zbog toga je za pravilnu, ponovnu upotrebu ovih modela na nekom drugom području potrebno ove modele ponovno trenirati podacima koji su prikupljeni na terenu.

Brzina obrade podataka pomoću izrađenih modela trenutno iznosi u prosjeku 3,2 snimke po sekundi što ukazuje da je analiza 1.826.664 snimke sakupljenih na VE Danilo 2015. godine trajala otprilike 6,6 dana. Isti postupak od strane stručnjaka trajao bi više mjeseci. Prilikom validacije modela primijećeno je postoji greška ručnog pregleda odnosno da je preciznost ručnog prepoznavanja snimki šišmiša u izvornom skupu za validaciju iznosila 95,19%, što je za 5,61% bolji rezultat od rezultata modela 2. Tako mala razlika govori u prilog primjenjivosti modela prezentiranih u ovom radu za automatsko prepoznavanje snimki šišmiša u velikim skupovima podataka.

5.1 Primjena korištenih metoda

Korištene metode imaju značajnu potencijalnu primjenu u znanstvenom istraživanju i praćenju šišmiša. Uz znanstvenu primjenu ove metode se mogu primijeniti u zaštiti populacija šišmiša na područjima na kojima su te populacije ugrožene (primjerice na području rada vjetroelektrane).

Okretanje lopatica rotora vjetroatregata može negativno utjecati na populaciju šišmiša oko području rada vjetroelektrana, zbog čega je česta mjera zaštite ograničavanje brzine vjetra na kojoj rotacija započinje na određenu kritičnu brzinu (ispod koje se zabranjuje rotacija turbina, zbog pojačane aktivnosti šišmiša na manjim brzinama vjetra). Ta brzina se opisuje kao minimalna brzina vjetra pri kojoj je aktivnost šišmiša dovoljno niska za početak okretanja rotora vjetroatregata (Rnjak i sur. 2016), što podrazumijeva prihvatljivi rizik od stradavanja. S obzirom da se najčešće propisuju za duža vremenska razdoblja (redovno nekoliko mjeseci godišnje, obuhvaćajući ljetno razdoblje s porodičnim kolonijama, te proljetne i jesenske migracije) Ovakve mjere zaštite šišmiša nerijetko znatno utječu na proizvodni učinak vjetroelektrane zbog smanjenja njezinog efektivnog vremena rada, a time i količina proizvedene električne energije.

Jedno od mogućih rješenja ovog problema bio bi automatizirani sustav za detekciju šišmiša koji bi u realnom vremenu pratio i određivao razinu aktivnost šišmiša u blizini vjetroatregata te bi time omogućio aktivaciju i deaktivaciju pojedinog vjetroatregata u odnosu na trenutnu situaciju na terenu. Time bi se smanjila smrtnost šišmiša, ali i gubici proizvodnje energije na prihvatljivu razinu. Izrađeni modeli bi se uz modifikaciju kontrole rada vjetroatregata (na način da se u njega integriraju s jedne strane automatizirani monitoring na stacionarnim betdetektorima, a s druge strane algoritmi za automatsko prepoznavanje glasanja šišmiša) mogli primijeniti u tu svrhu.


5.2 Nedostaci izrađenih modela

Iako modeli pokazuju zadovoljavajuću preciznost u pronalasku glasova šišmiša, u njihovom razvoju još uvijek ima mjesta za poboljšanja. Preciznost modela zasigurno bi porasla ukoliko bi se uz deskripciju snimaka pomoći SURF deskriptora primijenili i drugi poznati deskriptori računalnog vida poput SIFT, FREAK (Alahi i sur. 2012), ORB (Rublee i sur. 2011), BRISK (Leutenegger i sur. 2011) itd. Međutim, ukoliko bi se

povećao broj vrsta specifičnih značajki koje sustav treba izdvojiti iz pojedine snimke zasigurno bi došlo do usporavanja sustava tijekom rudarenja podataka. Rješenje tom problemu su modeli koji se ne temelje na izdvajanju specifičnih deskriptora, nego kao ulazne podatke direktno uzimaju cjelokupni odsječak spektrograma u željenom vremenu.

Takvi modeli se razvijaju se u dijelu strojnog učenja zvanog duboko učenje (eng. *deep learning*) i spadaju u neuronske mreže sastavljene od više slojeva sa sposobnosti učenja značajki direktno iz izvornih podataka (eng. *raw data*). U slučaju klasifikacije šišmiša ulazni podaci kod takvih neuronskih mreža su odsječci spektrograma na kojima se nalaze potencijalni zvukovi šišmiša.

Primjer neuronskih mreža ovakvih mogućnosti su konvolucijske neuronske mreže (eng. *convolutional neural networks, CNN*). Stvaranje konvolucijskih neuronskih mreža inspirirano je hijerarhijskom povezanosti neurona u primarnim vizualnim korteksu sisavaca (Ciresan i sur. 2011). Za razliku od neuronskih mreža izrađenih za treniranje modela 1 i modela 2 konvolucijske neuronske mreže su građene od više različitih vrsta slojeva. Najčešći od vrsta slojeva su konvolucijski slojevi (eng. *convolutional layers*), slojevi za udruživanje (eng. *pooling layers*) i potpuno spojeni slojevi (eng. *fully connected layers*) (Slika 5.1). Također za razliku od modela izrađenih u ovom diplomskom radu CNN modeli su idealni za klasifikaciju podataka na više klasa, što ih čini potencijalno primjenjivima na problem automatskog prepoznavanja vrsta šišmiša na temelju audio zapisa njihovog glasanja. Neuronske mreže ovog tipa već su u širokoj uporabi u medicini gdje služe za prepoznavanje različitih tipova bolesti (Esteva i sur. 2017), u ornitologiji gdje uspješno identificiraju ptice na temelju audio zapisa (Tóth i Czeba 2016), kao i u drugim znanstvenim područjima.



Slika 5.1 Shematski primjer modela temeljenog na konvolucijskoj neuronskoj mreži (CNN) za detekciju i identifikaciju šišmiša

6 Zaključci

Na temelju dobivenih rezultata u izdvajanju audio snimaka glasanja šišmiša iz velikog skupa podataka pomoću strojnog učenja mogu se donijeti sljedeći zaključci:

1. Općenito se može zaključiti da su metode strojnog učenja opisane u ovom diplomskom radu omogućile uspješno automatsko izdvajanje sekvenci glasanja šišmiša iz dugih nizova terenskih audio snimaka.
2. Korištene metode kvalitetom rezultata znatno nadilaze one koje se koriste u dostupnom komercijalnom softveru.
3. Korištene metode imaju značajan potencijal u terenskom praćenju šišmiša u znanstveno-istraživačke (npr. praćenje dinamike populacija u prostoru i vremenu) i/ili primijenjene svrhe (npr. dizajn mjera zaštite na lokacijama vjetroelektrana).
4. Izolacijom SURF značajki mogu se numerički opisati zvučne karakteristike šuma, te tako izolirati dijelove zvučnog zapisa koji sadrži glasanje šišmiša od ostatka audio snimke
5. SURF značajke izdvojene na temelju pojedinog potencijalnog glasa šišmiša omogućile su kvalitetniju klasifikaciju snimaka za razliku od SURF značajki izdvojenih na temelju cjelokupne snimke.
6. Podatkovno rudarenje velikih skupova podataka može uvelike olakšati analizu podataka sakupljenih kontinuiranim praćenjem aktivnosti šišmiša

7 Literatura

- Alahi, Alexandre, Raphael Ortiz, i Pierre Vandergheynst. 2012. „Freak: Fast retina keypoint“. U *Computer vision and pattern recognition (CVPR), 2012 IEEE*, 510–517. IEEE.
- Anatolović, Jasna, i Nikola Tvrtković. 2006. *Crvena knjiga sisavaca Hrvatske*. Zagreb: Ministarstvo kulture, Državni zavod za zaštitu prirode.
- Baerwald, Erin F., Genevieve H. D'Amours, Brandon J. Klug, i Robert M. R. Barclay. 2008. „Barotrauma is a significant cause of bat fatalities at wind turbines“. *Current Biology* 18 (16): R695–96. doi:10.1016/j.cub.2008.06.029.
- Barataud, Michel. 2015. *Acoustic Ecology of European Bats, Species Identification, Study of Their Habitats and Foraging Behaviour*. Biotope, Meze; Muséum national d'histoire naturelle, Paris (Inventaires et biodiversité series).
- Bay, Herbert, Tinne Tuytelaars, i Luc Van Gool. 2006. „Surf: Speeded up robust features“. U *European conference on computer vision*, 404–417. Springer.
- Bernard, Enrico, i M Brock Fenton. 2002. „Species Diversity of Bats (Mammalia: Chiroptera) in Forest Fragments, Primary Forests, and Savannas in Central Amazonia, Brazil“. *Canadian Journal of Zoology* 80 (6): 1124–40. doi:10.1139/z02-094.
- Blehert, D. S., A. C. Hicks, M. Behr, C. U. Meteyer, B. M. Berlowski-Zier, E. L. Buckles, J. T. H. Coleman, i sur. 2009. „Bat White-Nose Syndrome: An Emerging Fungal Pathogen?“. *Science* 323 (5911): 227–227. doi:10.1126/science.1163874.
- Ciresan, Dan C., Ueli Meier, Jonathan Masci, Luca Maria Gambardella, i Jürgen Schmidhuber. 2011. „Flexible, high performance convolutional neural networks for image classification“. U *Proceedings-International Joint Conference on Artificial Intelligence*, 22:1237. IJCAI.
- Deng, Li. 2014. „Deep Learning: Methods and Applications“. *Foundations and Trends® in Signal Processing* 7 (3–4): 197–387. doi:10.1561/20000000039.
- Enercon. 2016. „E-82 Enercon Wind Turbine Specifications“. *E-82 Enercon Wind Turbine Specifications*. studeni 24. <http://www.enercon.de/en/products/ep-2/e-82/>.
- Ess, Andreas, Tinne Tuytelaars, i Luc Van Gool. 2008. „Speeded-up robust features (SURF)“. *Computer vision and image understanding* 110 (3): 346–359.
- Esteva, Andre, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau, i Sebastian Thrun. 2017. „Dermatologist-level classification of skin cancer with deep neural networks“. *Nature*, siječanj. doi:10.1038/nature21056.
- Fenton, M. Brock. 1997. „Science and the conservation of bats“. *Journal of mammalogy* 78 (1): 1–14.
- Fenton, M. Brock, i Nancy B. Simmons. 2015. *Bats: A World of Science and Mystery*. University of Chicago Press.
- Funayama, Ryuji, Hiromichi Yanagihara, Gool Luc Van, Tinne Tuytelaars, i Herbert Bay. 2009. Robust Interest Point Detector and Descriptor. US2009238460 (A1), issued 24. rujan 2009.

- Gerhard, David. 2003. „Audio Signal Classification: History and Current Techniques“. Technical report TR-CS 2003-07. Regina: Dept. of Computer Science, University of Regina.
- Hayes, Mark A. 2013. „Bats Killed in Large Numbers at United States Wind Energy Facilities“. *BioScience* 63 (12): 975–79. doi:10.1525/bio.2013.63.12.10.
- Hunter, John D. 2007. „Matplotlib: A 2D Graphics Environment“. *Computing in Science & Engineering* 9 (3): 90–95. doi:10.1109/MCSE.2007.55.
- Hutson, A.M. 2008. „Rhinolophus Mehelyi: The IUCN Red List of Threatened Species 2008“. <http://www.iucnredlist.org/details/19519/0>.
- Jennings, N., S. Parsons, i M. J.O. Pocock. 2008. „Human vs. machine: identification of bat species from their echolocation calls by humans and by artificial neural networks“. *Canadian Journal of Zoology* 86 (5): 371–77. doi:10.1139/Z08-009.
- Jones, Eric, Travis Oliphant, i Pearu Peterson. 2001. „SciPy: Open Source Scientific Tools for Python“. <http://www.scipy.org/>.
- Leutenegger, Stefan, Margarita Chli, i Roland Y. Siegwart. 2011. „BRISK: Binary robust invariant scalable keypoints“. U *2011 IEEE International Conference on Computer Vision (ICCV)*, 2548–2555. IEEE.
- Lucas, T. 2000. „Bat identification with Gaussian process learning“. *University College London*.
- Mirzaei, Golrokh, Mohammad Wadood Majid, Mohsin M. Jamali, Jeremy Ross, J. Frizado, Peter V. Gorsevski, i V. Bingman. 2011. „The application of Evolutionary Neural Network for bat echolocation calls recognition“. U *The 2011 International Joint Conference on Neural Networks (IJCNN)*, 1106–1111. IEEE.
- O’Shea, Thomas J., Paul M. Cryan, David T.S. Hayman, Raina K. Plowright, i Daniel G. Streicker. 2016. „Multiple Mortality Events in Bats: A Global Review“. *Mammal Review* 46 (3): 175–90. doi:10.1111/mam.12064.
- Papadatou, Eleni, Roger K. Butlin, i John D. Altringham. 2008. „Identification of Bat Species in Greece from Their Echolocation Calls“. *Acta Chiropterologica* 10 (1): 127–43. doi:10.3161/150811008X331153.
- Parsons, S., i G. Jones. 2000. „Acoustic Identification of Twelve Species of Echolocating Bat by Discriminant Function Analysis and Artificial Neural Networks“. *The Journal of Experimental Biology* 203 (Pt 17): 2641–56.
- Pedregosa, Fabian, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, i sur. 2011. „Scikit-learn: Machine Learning in Python“. *Journal of Machine Learning Research* 12 (listopad): 2825–2830.
- Popa-Lisseanu, Ana G., Antonio Delgado-Huertas, Manuela G. Forero, Alicia Rodríguez, Raphaël Arlettaz, i Carlos Ibáñez. 2007. „Bats’ Conquest of a Formidable Foraging Niche: The Myriads of Nocturnally Migrating Songbirds“. *PLoS ONE* 2 (2). doi:10.1371/journal.pone.0000205.
- Redgwell, Robert D., Joseph M. Szewczak, Gareth Jones, i Stuart Parsons. 2009. „Classification of Echolocation Calls from 14 Species of Bat by Support Vector Machines and Ensembles of Neural Networks“. *Algorithms* 2 (3): 907–24. doi:10.3390/a2030907.

- Rnjak, Dina, Nikola Hanžek, Goran Rnjak, Vida Zrnčić, Josip Križan, Goran Gašparac, Ana Jurjević, i sur. 2016. „Završni i godišnji izvještaj 2015./2016. - tijekom korištenja vjetroelektrane“. Zagreb: GEONATURA.
- Ruble, Ethan, Vincent Rabaud, Kurt Konolige, i Gary Bradski. 2011. „ORB: An efficient alternative to SIFT or SURF“. U *Computer Vision (ICCV), 2011 IEEE International Conference on*, 2564–2571. IEEE.
- Russo, Danilo, i Gareth Jones. 2002. „Identification of twenty-two bat species (Mammalia: Chiroptera) from Italy by analysis of time-expanded recordings of echolocation calls“. *Journal of Zoology* 258 (1): 91–103. doi:10.1017/S0952836902001231.
- Sivic, J., i A. Zisserman. 2009. „Efficient Visual Search of Videos Cast as Text Retrieval“. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 31 (4): 591–606. doi:10.1109/TPAMI.2008.111.
- Sleeman, Jonathan. 2016. „White-Nose Syndrome Updates for the 2015/2016 Surveillance Season“.
- Stathopoulos, Vassilos, Veronica Zamora-Gutierrez, Kate E. Jones, i Mark Girolami, ur. 2014. „Bat Call Identification with Gaussian Process Multinomial Probit Regression and a Dynamic Time Warping Kernel“. U . Reykjavik, Iceland: AISTATS.
- Teeling, E. C. 2005. „A Molecular Phylogeny for Bats Illuminates Biogeography and the Fossil Record“. *Science* 307 (5709): 580–84. doi:10.1126/science.1105113.
- Tóth, Bálint Pál, i Bálint Czéba. 2016. „Convolutional neural networks for large-scale bird song classification in noisy environment“. U *Working notes of CLEF conference*, 1609:560–68. LifeCLEF. Évora, Portugal: CEUR WP.
- Voigt, Christian C., Linn S. Lehnert, Gunars Petersons, Frank Adorf, i Lothar Bach. 2015. „Wildlife and Renewable Energy: German Politics Cross Migratory Bats“. *European Journal of Wildlife Research* 61 (2): 213–19. doi:10.1007/s10344-015-0903-y.
- Walt, Stéfan van der, S Chris Colbert, i Gaël Varoquaux. 2011. „The NumPy Array: A Structure for Efficient Numerical Computation“. *Computing in Science & Engineering* 13 (2): 22–30. doi:10.1109/MCSE.2011.37.
- Walters, Charlotte L., Robin Freeman, Alanna Collen, Christian Dietz, M. Brock Fenton, Gareth Jones, Martin K. Obrist, i sur. 2012. „A Continental-Scale Tool for Acoustic Identification of European Bats“. Uredio Jeroen Minderman. *Journal of Applied Ecology* 49 (5): 1064–74. doi:10.1111/j.1365-2664.2012.02182.x.

8 Prilozi

8.1 Popis šišmiša Hrvatske

Tablica 8.1 Popis vrsta šišmiša u Hrvatskoj, njihov status u Hrvatskoj (R = rezidentna vrsta; RE = regionalno izumrla; M = stalna vrsta u migraciji ili na zimovanju) i kategorije ugroženosti prema IUCN-u u Hrvatskoj (RE = regionalno izumrla; EN = ugrožene vrste, VU = rizične vrste, DD = nedovoljno poznate vjerojatno ugrožene vrste, NT = potencijalno ugrožene) (Anatolović i Tvrtković 2006)

LATINSKI NAZIV	HRVATSKI NAZIV	STATUS VRSTE U HR	IUCN KATEGORIJA UGROŽENOSTI
BARBASTELLA BARBASTELLUS , (SCHREBER 1774.)	Širokouhi mračnjak	R	DD
EPTESICUS NILSSONII , (KEYSLERING ET BLASIUS, 1839.)	Kasni noćnjak	M	
EPTESICUS SEROTINUS , (SCHREBER 1774.)	Sjeverni noćnjak	R	
HYPUSUGO SAVII , (BONAPARTE, 1837.)	Primorski šišmiš	R	
MINIOPTERUS SCHREBERSII , (KUHL, 1817.)	Dugokrili pršnjak	R, M	EN
MYOTIS ALCATHOE , (VON HELVENSEN ET HELLER, 2001.)	Mali brkati šišmiš	?	
MYOTIS AURASCENS , (KUZYAKIN, 1835.)	Kuzjakinov šišmiš	R	
MYOTIS BLYTHII , (MONTICELLI, 1885.)	Oštrouhi šišmiš	R	
MYOTIS BECHSTEINII , (KUHL, 1817.)	Velikouhi šišmiš	R	
MYOTIS BRANDTII , (EVERSMANN, 1837.)	Brandtov šišmiš	R	
MYOTIS CAPACCINII , (BONAPARTE, 1837.)	Dugonogi šišmiš	R	EN
MYOTIS DASYNEME , (BOIE, 1825.)	Močvarni šišmiš	R, M	DD
MYOTIS DAUBENTONII , (KUHL, 1817.)	Riječni šišmiš	R	
MYOTIS EMARGINATUS , (E. GEOFFROY, 1806.)	Riđiši šimiš	R	NT
MYOTIS MYOTIS , (BORKHAUSEN, 1797.)	Veliki šišmiš	R	NT
MYOTIS MYSTACINUS , (KUHL, 1817.)	Brkati šišmiš	R	
MYOTIS NATTERERI , (KUHL, 1817.)	Resasti šišmiš	R	

NYCTALUS NOCTULA , (SCHREBER, 1780.)	Rani večernjak	R, M	
NYCTALUS LASIOPTERUS , (SCHREBER, 1780.)	Veliki večernjak	R	DD
NYCTALUS LEISLERI , (KUHL, 1817.)	Mali večernjak	R, M	NT
PIPISTRELLUS KUHLII , (KUHL, 1817.)	Bjelorubi šišmiš	R	
PIPISTRELLUS NATHUSII , (KEYSLERING ET BLASIUS, 1839.)	Mali šumski šišmiš	M	
PIPISTRELLUS PIPISTRELLUS , (SCHREBER, 1780.)	Patuljasti šišmiš	R	
PIPISTRELLUS PYGMAEUS , (LEACH, 1825.)	Močvarni patuljasti šišmiš	R	
PLECOTUS AURITUS , (LINNAEUS, 1758.)	Smeđi dugoušan	R	
PLECOTUS AUSTRIACUS , (J. B. FISCHER, 1829.)	Sivi dugoušan	R	EN
PLECOTUS KOLOMBATOVICI , (ĐULIĆ, 1980.)	Kolombatoviće dugoušan	R	DD
PLECOTUS MACROBULLARIS , (KUZYAKIN, 1965.)	Gorski dugoušan	R	DD
RHINOLOPHUS BLASII , (PETERS, 1866.)	Sredozemni potkovnjak	R	VU
RHINOLOPHUS EURYALE , (BLASIUS, 1835.)	Južni potkovnjak	R	VU
RHINOLOPHUS FERRUMEQUINUM , (SCHREBER, 1774.)	Veliki potkovnjak	R	NT
RHINOLOPHUS HIPPOSIDEROS , (BECHSTEIN, 1800.)	Mali potkovnjak	R	NT
RHINOLOPHUS MEHELY , (MATSCHIE, 1901.)	Meheljev potkovnjak	RE	RE
TADARTIDA TENIOTIS , (RAFINESQUE, 1814.)	Sredozemni slobodnorepac	R	
VESPERTILIO MURINUS , (LINNAEUS, 1758.)	Dvobojni šišmiš	M	

8.2 Informatičko okruženje za analizu snimaka ultrazvuka

Informatičko okruženje za bioakustičnu analizu razvijeno je za korisnike koji su upoznati s osnovama i principima rada Python programskog jezika. Osnova okruženja su Numpy (van der Walt, Colbert, i Varoquaux 2011), Scipy (Jones, Oliphant, i Peterson 2001), scikit-image (Pedregosa i sur. 2011) i Matplotlib (Hunter 2007) Python paketi. Paket omogućuje učitavanje snimke u vektorski oblik iz WAV formata, izradu spektrograma, očitavanje parametara snimanja snimke (učestalost uzorkovanja, trajanje), izrada prosječne energetske krivulje snimke, čišćenje sistemskog šuma i mnoge druge radnje.

8.2.1 Primjeri korištenja paketa:

Primjer učitavanja paketa pomoću programskog jezika Python:

```
import komori
# ili
import komori as km
```


Primjer učitavanja snimke pomoću km.load() metode:

```
import komori as km
dur, sr, y = km.load("snimka.wav")
print dur, sr, y

# Rezultat:
>> 3.53215ms 384kHz [2., 3., 4., ... 3., 6., 6.]
```

Primjer vizualizacije spektrograma:



```
import komori as km
import matplotlib.pyplot as plt
dur, sr, y = km.load("snimka.wav")
spektrogram = km.spectrogram(y, sr, 768, 512, "hanning", savepath="spektrogram.png")
km.show(spektrogram)
```



Slika 8.1 Primjer spektrograma proizvedenog pomoću okruženja za analizu snimaka ultrazvuka

Primjer čišćenja sistemskog šuma pomoću okruženja za analizu ultrazvuka:

```
import komori as km
dur, sr, y = km.load("snimka.wav")
spektrogram = km.spectrogram(y, sr, 512, 64, "hanning")
km.show(spektrogram)
spektrogram = km.rm_noise(spektrogram)
km.show(spektrogram)
```




Slika 8.2 Uklanjanje sistemskog šuma

8.3 Pregled specifičnih zvučnih zapisa iz skupa za treniranje modela


Ovaj prilog sadrži vizualizacije isječaka zvukova iz skupa podataka za treniranje. Prikazani spektrogrami izrađeni su različitim parametrima STFT-a.

8.3.1 Šišmiši


Ovaj prilog sadrži spektrograme snimki snimljene ultrazvučnim detektorima u blizini VE Danilo na kojima su prisutni šišmiši.




Slika 8.3 Glas šišmiša *Barbastella barbastellus*





Slika 8.4 Glasovi šišmiša koji spada u fonetsku skupinu *Eptesicus-Nyctalus-Vespertilio*

Slika 8.5 Glasovi šišmiša *Hypsugo savii*





Slika 8.6 Glasovi šišmiša *Myotis* sp.

Slika 8.7 Glasovi šišmiša *Myotis sp.*




Slika 8.8 Glasovi šišmiša *Myotis* sp.


Slika 8.9 Glasovi šišmiša *Nyctalus noctula*




Slika 8.10 Glasovi šišmiša koji spada u fonetsku skupinu
Pipistrellus knuili – *Pipistrellus nathusi*




Slika 8.11 Glasovi šišmiša koji spada u fonetsku skupinu Pipistrellus khulii – Pipistrellus nathusi



Slika 8.12 Glasovi šišmiša *Pipistrellus khuii*




Slika 8.13 Glasovi šišimiša *Pipistrellus pipi strellus*




Slika 8.14 Glasovi šišmiša rodova *Myotis* i *Rhinolophus* na jednoj snimci.


Crvena strelica označava glas vrste koja pripada rodu *Rhinolophus*.

Plava strelica pokazuje glas vrste koja pripada rodu *Myotis*.


Slika 8.15 Glasovi šišmiša *Rhinolophus blasii*




Slika 8.16 Glasovi šišmiša *Rhinolophus euryale*



Slika 8.17 Glasovi šišmiša *Rhinolophus ferrumequinum*




Slika 8.18 Glasovi šišmiša *Rhinolophus hipposideros*


Slika 8.19 Glasovi šišmiša *Tadarida teniotis*

8.3.2 Šumovi


Ovaj prilog sadrži spektrograme najčešćih primjera zvukova koji su uzrokovali lažnu aktivaciju ultrazvučnih detektora.



Slika 8.20 Spektrogram zvuka okretanja gondole vjetroagregata



Slika 8.21 Spektrogram zvuka koji proizvode insekti



Slika 8.22 Primjer zvuka sa snažnim okomitim oblikom - okomiti šum

8.4 Izvori slika

Slika 1.3 – Slika A:

<http://www.bio.bris.ac.uk/research/bats/China%20bats/tadaridateniotis.htm>,

31.12.2016

Slika 1.3 – Slika B:

<http://www.bio.bris.ac.uk/research/bats/China%20bats/rhinolophusferrumequinum.htm>, 31.12.2016