

Analiza značajki glasanja dupina korištenjem toplinske karte

Jerinić, Jurica

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:168:982942>

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

Download date / Datum preuzimanja: **2025-03-14**



Repository / Repozitorij:

[FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1409

**ANALIZA ZNAČAJKI GLASANJA DUBINA KORIŠTENJEM
TOPLINSKE KARTE**

Jurica Jerinić

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1409

**ANALIZA ZNAČAJKI GLASANJA DUBINA KORIŠTENJEM
TOPLINSKE KARTE**

Jurica Jerinić

Zagreb, lipanj 2024.

ZAVRŠNI ZADATAK br. 1409

Pristupnik: **Jurica Jerinić (0036539008)**
Studij: Elektrotehnika i informacijska tehnologija i Računarstvo
Modul: Računarstvo
Mentor: prof. dr. sc. Nikola Mišković

Zadatak: **Analiza značajki glasanja dubina korištenjem toplinske karte**

Opis zadatka:

U trenutnim istraživanjima nedostaje analiza značajki u glasanjima dubina. Dok su prethodna istraživanja istraživala prepoznavanje samog glasanja, odabir značajki uglavnom je bio heuristički, temeljen na identifikaciji karakterističnih obilježja. U završnom radi potrebno je poboljšati pristup odabira značajki. Korištenjem toplinskih karata, treba identificirati specifična područja unutar spektrograma koja su ključna za uspješno prepoznavanje karakterističnog glasanja dubina. Razvijena metodologija treba ponuditi sustavniji, podatkovno vođen, pristup identifikaciji značajki. Glavni cilj je primijeniti toplinske karte na detektor glasanja dubina i odrediti najvažnije karakteristike ključne za preciznost prepoznavanja. Nadalje, potrebno je razviti čvrste mjere za usporedbu rezultata dobivenih toplinskim kartama s rezultatima generiranim mrežom pažnje. Ova usporedna analiza obećava rasvjetljavanje učinkovitosti i pouzdanosti toplinskih karata kao alata za odabir značajki u kontekstu prepoznavanja dupinskog glasanja.

Rok za predaju rada: 14. lipnja 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

**ANALIZA ZNAČAJKI GLASANJA DUPINA
KORIŠTENJEM TOPLINSKE KARTE**

Jurica Jerinić

Zagreb, lipanj 2024.

*Special thanks to my mentor, Roe Diamant,
for his assistance in writing this paper.*

UVOD

"Toplinska karta" je tehnika vizualizacije podataka koja prikazuje pažnju koju neuronska mreža posvećuje svakoj ulaznoj varijabli. Za ulaznu sliku, toplinska karta se prikazuje kao magnituda varijable u boji u dvije dimenzije. Ovo omogućuje gledatelju lakše razumijevanje složenih skupova podataka ističući područja interesa s varirajućim intenzitetima boje. Toplinske karte su posebno učinkovite u ilustriranju gustoće ili intenziteta podataka unutar određenog područja, čime se jednostavno mogu identificirati obrasci, trendovi i anomalije na prvi pogled.

Toplinske karte široko se koriste u različitim područjima u svrhe različitih analiza. U poslovanju se koriste za analizu ponašanja potrošača na web stranicama, prikazujući koje dijelove stranice privlači najviše pažnje. U geografiji, toplinske karte pomažu u vizualizaciji gustoće stanovništva, uzoraka prometa i vremenskih uvjeta. U zdravstvu mogu ilustrirati širenje bolesti ili intenzitet simptoma u različitom području. Svestranost i intuitivna priroda toplinskih karata čine ih ključnim alatom za analizu podataka, pružajući uvide koji bi mogli biti propušteni tradicionalnim numeričkim reprezentacijama.

Potreba za korištenjem toplinskih karata proizlazi iz njihove sposobnosti pojednostavljenja interpretacije velikih i složenih skupova podataka. Pretvaranjem podataka u vizualne formate, toplinske karte pomažu u brzom prepoznavanju područja koja zahtijevaju pažnju, što olakšava donošenje boljih odluka. Također omogućuju učinkovitu komunikaciju rezultata široj publici, uključujući one koji nemaju specijalizirano znanje iz područja analize podataka.

U ovom radu istražujemo toplinsku kartu neuronske mreže usmjerene na detekciju zvižduka dupina. Iako su brojni radovi (npr. [1]) proučavali analizu značajki zvižduka za detekciju i klasifikaciju, prevladavajuće ograničenje i dalje postoji: nedostaje sustavna analiza koji su dijelovi zvižduka dupina ključni za detekciju zvižduka. Takva analiza omogućila bi razumijevanje ne samo rada neuronske mreže, već i specifične strukture zvižduka dupina. Ovo je posebno važno pri pokušaju generalizacije detekcije za različite skupove podataka, vrste dupina ili akustičnu opremu. Toplinska karta ima potencijal odgovoriti na takva pitanja.

Fokusiramo se na tehniku detekcije u [6] koja uključuje prethodno treniranje neuronsku mrežu VGG16 čiji je ulaz spektrogram sumnjivog područja interesa (ROI). Spektrogram se tretira kao RGB slika čije x, y, z koordinate predstavljaju redom vrijeme, frekvenciju i akustičnu jačinu ulaznog signala. Upotreba spektrograma kao ulaza ima potencijal prepoznati strukturu zvižduka.

ISTRAŽIVANJE O TOPLINSKIM KARTAMA

- **Predviđanje i strojno učenje u izravnom marketingu za predviđanje pretplata na bankovne oročene depozite [2]**

U ovom istraživanju toplinske karte se koriste kao ključni alat za vizualizaciju unutar faze eksploratorne analize podataka (EDA). Konkretno, toplinske karte korelacija koriste se za analizu odnosa između različitih varijabli u skupu podataka. Ove toplinske karte vizualiziraju snagu i smjer korelacija koristeći gradacije boja, što omogućuje jednostavno prepoznavanje snažnih pozitivnih ili negativnih korelacija. Korištenje toplinskih karata korelacija pomaže otkriti skrivene obrasce i odnose unutar podataka, pružajući vrijedne uvide koji mogu značajno utjecati na uspjeh kampanja izravnog marketinga.

Primarna prednost korištenja toplinskih karata korelacija u ovom kontekstu je njihova sposobnost pojednostavljenja razumijevanja složenih odnosa između više varijabli. One nude jasnu i intuitivnu vizualnu reprezentaciju, što je osobito korisno za prepoznavanje ključnih faktora koji utječu na pretplate na bankovne oročene depozite. Međutim, jedna od ograničenja je da toplinske karte korelacija mogu biti obmanjujuće ako se ne koriste s odgovarajućim statističkim kontekstom. Bez pravilne interpretacije, vizualna reprezentacija može sugerirati lažne korelacije ili zanemariti važne nijanse.

Sveukupno, korištenje toplinskih karata korelacija u radu poboljšava analitički proces pružajući vizualni alat za istraživanje i razumijevanje složenih ovisnosti unutar skupa podataka, čime se omogućuje donošenje boljih odluka u razvoju prediktivnih modela za strategije izravnog marketinga u bankarskom sektoru.

- **Strojno učenje u odabiru visokoučinkovitih elektro katalizatora za redukciju CO₂ [3]**

U ovom istraživanju toplinske karte koriste se za vizualizaciju predviđene katalitičke aktivnosti i svojstava različitih elektro katalizatora. Ove toplinske karte generiraju se korištenjem modela strojnog učenja kako bi se pružila reprezentacija podataka kodirana bojom, gdje intenzitet boje odgovara razini aktivnosti ili svojstvu od interesa. Korištenje toplinskih karata omogućuje istraživačima brzo prepoznavanje materijala i njihovih odgovarajućih površinskih mjesta koja su najperspektivnija za redukciju CO₂.

Ključna prednost korištenja toplinskih karata u ovom kontekstu je njihova sposobnost pojednostavljenja analize velikih i složenih skupova podataka, što olakšava otkrivanje trendova i značajnih obrazaca. Ova vizualna reprezentacija pomaže u bržem prepoznavanju najučinkovitijih katalizatora, čime se ubrzava proces eksperimentalnog istraživanja. Toplinske karte također pružaju jednostavan način za usporedbu performansi različitih materijala, ističući one s optimalnim adsorpcijskim energijama i katalitičkim svojstvima.

- **Hibridni Model Dubokog Učenja Za Unutarnje Pozicioniranje Pomoću Wi-Fi RSSI Toplinskih Mapa Za Autonomne Primjene [4]**

U ovom radu, toplinske mape RSSI koriste se za poboljšanje točnosti sustava unutarnjeg pozicioniranja. Istraživači su razvili Hibridni Model Dubokog Učenja (HDLM) koji kombinira Konvolucijske Neuronske Mreže (CNN) i Long Short-Term

Memory (LSTM) mreže. Toplinske mape RSSI, koje vizualno prikazuju varijacije jačine signala na različitim lokacijama, koriste se za treniranje HDLM-a. Ovaj pristup koristi prostorne informacije zabilježene u toplinskim mapama kako bi se napravila točna predviđanja o pozicijama korisnika u unutarnjim okruženjima. Primarna prednost korištenja toplinskih mapa RSSI u ovom kontekstu je značajno poboljšanje točnosti lokalizacije. Pretvaranjem sirovih RSSI signala u toplinske mape, sustav može bolje upravljati fluktuacijama signala i smetnjama u okolišu, što dovodi do pouzdanijih procjena pozicija. CNN komponenta HDLM-a izvrsno izvlači prostorne značajke iz toplinskih mapa, dok LSTM komponenta omogućuje modelu razumijevanje vremenskih ovisnosti između tih značajki.

Komponenta učinkovito hvata vremenske ovisnosti, čineći kombinirani model robusnim i preciznim u svojim predviđanjima. Međutim, postoje neka ograničenja ovog pristupa. Jedan od glavnih izazova je povećani računalni trošak povezan s kombiniranom arhitekturom CNN-a i LSTM-a. Ova složenost zahtijeva značajnu računalnu snagu, što možda neće biti izvedivo za aplikacije u stvarnom vremenu s ograničenim resursima. Dodatno, proces treniranja HDLM modela je dugotrajan zbog velikog skupa podataka i složene prirode uključenih neuronskih mreža. Konačno, točnost sustava pozicioniranja uvelike ovisi o kvaliteti generiranih toplinskih mapa RSSI, što može biti pod utjecajem preciznosti prikupljanja i obrade RSSI podataka. Sveukupno, korištenje toplinskih mapa RSSI u kombinaciji s hibridnim modelom dubokog učenja nudi moćnu metodu za poboljšanje točnosti unutarnje lokalizacije, demonstrirajući značajne prednosti u odnosu na tradicionalne pristupe koji se oslanjaju na sirove RSSI vrijednosti.

- **Komparativno Istraživanje Algoritama Strojnog Učenja Za Predviđanje Raka Dojke [5]**

U ovom radu toplinske mape koriste se kao integralni dio procesa analize podataka za vizualizaciju interakcija između različitih značajki u skupu podataka. Ove toplinske mape koriste gradacije boja kako bi prikazale snagu i smjer interakcija, pružajući intuitivan vodič za prepoznavanje značajnih odnosa između varijabli.

Prednost korištenja toplinskih mapa u ovom istraživanju je njihova sposobnost da poboljšaju interpretaciju složenih podataka. Omogućuju istraživačima da brzo identificiraju koje značajke imaju najveći utjecaj na predviđanje raka dojke, olakšavajući ciljanu izradu modela strojnog učenja. Toplinske mape također pomažu u otkrivanju skrivenih obrazaca i interakcija između varijabli koje možda nisu evidentne kroz tradicionalne statističke metode. To može dovesti do informiranijeg odabira značajki i boljih performansi modela.

Međutim, postoje neka ograničenja u korištenju toplinskih mapa. Jedan od glavnih nedostataka je preopterećenje kada se radi s velikim brojem varijabli, što otežava točnu interpretaciju rezultata. Dodatno, toplinske mape ponekad mogu predložiti korelacije koje nisu statistički značajne ako nisu pravilno strukturirane s potpornom statističkom analizom. Unatoč tim ograničenjima, korištenje toplinskih mapa u ovom istraživanju poboljšava fazu analize podataka pružajući vrijedne uvide u korelacije skupa podataka i usmjeravajući razvoj točnijih modela strojnog učenja za predviđanje raka dojke.

OPIS BAZE PODATAKA

Naša baza podataka snimljena je u Crvenom moru, Eilat, Izrael. Potpuni opis baze podataka naveden je u [6] i sažet ovdje radi potpunosti. Akustični zapisi dobiveni su pomoću samostalno izrađenog akustičkog snimača koji je uključivao Raspberry Pi-Zero, zvučnu karticu koja uzorkuje pri 96 kHz@3B, skup baterija, dva hidrofona Geospectrum M18 te kućište izrađeno po mjeri. Snimač je bio pričvršćen roniocima na dubini od 50 m, otprilike 200 m udaljeno od grebena delfina u Eilatu, Izraelu. Pomoću plutajućih naprava, hidrofoni su bili postavljeni 1.5 m iznad morskog dna. Snimač je kontinuirano snimao FLAC datoteke tijekom 27 dana tijekom ljetnog razdoblja 2021. godine. Nakon povratka, podaci su prošli postupak osiguranja kvalitete (QA) radi uklanjanja sporadičnih prekida i dugih razdoblja buke. QA je uključivala eliminaciju prolaznih šumova pomoću valne denoizacije te identifikaciju i odbacivanje prekida događaja pomoću pragova i uklanjanja pristranosti. Podaci su

prošli filtriranje pojasnog opsega (5 kHz - 20 kHz) kako bi odgovarali zvižduku dupina i bijeli filter za korekcije hidrofona i zvučne kartice. Snimljeni zvuk, prosječno kroz dva kanala, obrađen je radi stvaranja spektrograma, smanjenja buke i odbacivanja odstupanja na temelju duljine signala. Spektrogrami zvižduka dupina generirani su pomoću MATLAB-a s mapom boja u nijansama sive, frekvencijom pretvorenom u kHz, a spektralna gustoća snage u dB, fokusirajući se na raspon 3-20 kHz, pri čemu su vrijednosti piksela slike normalizirane.

Spektrogrami su ručno označeni u dva koraka: označavanje za obuku i provjera označavanja. Označavanje za obuku uključivalo je označavanje spektrograma trajanja 5 sekundi tijekom 10 dana kako bi se obučio preliminarni klasifikator dubokog učenja. Ovaj klasifikator zatim je korišten za učinkoviti odabir novih dijelova snimaka s potencijalnim zvukovima dupina. U fazi validacije, provjera pozitivnih uzoraka identificiranih preliminarnim klasifikatorom pojednostavila je proces. U posljednjoj fazi pripreme, skup podataka je podijeljen na dvije odvojene binarne klasifikacije: zvižduk, koji predstavlja pozitivnu klasu, i buka, negativnu klasu. Skup podataka bio je spreman za upotrebu u treningu modela.

RJEŠENJE

Za ovaj projekt odabrane su Grad-CAM (Gradient-weighted Class Activation Mapping) toplinske mape zbog njihove jasne i intuitivne metode vizualizacije dijelova spektrogramskih slika koji su najznačajniji za detekciju zvižduka dupina. Grad-CAM toplinske mape koriste gradijente ciljnih klase, koji teku u završni konvolucijski sloj, kako bi proizvele lokalizacijsku mapu koja ističe važne regije na slici. Ova metoda pomaže u razumijevanju procesa donošenja odluka neuronske mreže, olakšavajući identifikaciju i fokusiranje na najbitnije značajke za točnu detekciju. Korištenjem Grad-CAM-a možemo osigurati interpretabilniji i transparentniji model, što je ključno za poboljšanje točnosti detekcije i dobivanje uvida u temeljne obrasce unutar podataka spektrograma.

Opis arhitekture

Arhitektura našeg rješenja temelji se na VGG16 modelu, široko korištenoj konvolucijskoj neuronskoj mreži, koja je podešena za binarnu klasifikaciju.

Arhitektura mreže:

1. Ulazni sloj: Prima prethodno obrađene spektrogramске slike veličine 224x224x3. Ovaj korak uključuje obrezivanje bijelih rubova i promjenu veličine slika na potrebne dimenzije.
2. VGG16 bazni model: Jezgra arhitekture, prethodno trenirana na ImageNet skupu podataka, bez vršnih potpuno povezanih slojeva. Konvolucijski slojevi ovog modela koriste se za izdvajanje bogatih reprezentacija značajki iz spektrograma.
3. Prilagođeni slojevi
 - Sloj za ravnjanje (Flatten Layer): Pretvara 3D značajke iz VGG16 modela u 1D vektore, pripremajući ih za guste slojeve.
 - Gusti sloj (Dense Layer): Potpuno povezani sloj s 512 jedinica i ReLU aktivacijom, koji uči složene uzorke iz izdvojenih značajki.
 - Izlazni sloj (Output Layer): Jedan neuron sa sigmoid aktivacijom koji daje binarnu klasifikaciju, ukazujući na prisutnost ili odsutnost zvižduka dupina.
4. Generiranje toplinske mape:
 - Ekstrakcija izlaza slojeva (Layer Outputs Extraction): Izlazi iz svih konvolucijskih slojeva se ekstrahiraju kako bi se generirale toplinske mape.
 - Kreiranje toplinske mape (Heat Map Creation): Grad-CAM toplinske mape se kreiraju koristeći gradijente ciljne klase koji ulaze u završni konvolucijski sloj, ističući regije spektrograma koje najviše doprinose odluci o detekciji.

Detaljan tijek rada

1. Predobrada podataka: Skup podataka se dijeli na skup za treniranje i skup za validaciju. Slike se argumentiraju tehnikama poput ponovnog skaliranja, zumiranja i horizontalnog okretanja. Dodatno, prilagođena funkcija za predobradu obrezuje bijele rubove sa slika i mijenja njihovu veličinu na 224x224 piksela.

2. Treniranje modela: VGG16 model se fino podešava zamrzavanjem svoje konvolucijske baze i dodavanjem prilagođenih gustih slojeva. Model se konfigurira s Adam optimizatorom i binarnom cross-entropy funkcijom gubitka. Zatim se trenira određeni broj epoha koristeći pripremljene generatore podataka.
3. Vizualizacija toplinskih mapa: Nakon treniranja, izlazi konvolucijskih slojeva modela koriste se za generiranje Grad-CAM toplinskih mapa. Ove toplinske mape vizualiziraju regije spektrograma na koje se model fokusira prilikom detekcije zvižduka dupina. Proces uključuje korištenje gradijenata ciljne klase za kreiranje lokalizacijske mape, ističući značajne regije na ulaznim slikama.

Korištenjem VGG16 modela i Grad-CAM toplinskih mapa, ovo rješenje nudi snažnu metodu za poboljšanje točnosti i interpretabilnosti detekcije zvižduka dupina. Arhitektura osigurava da se značajne značajke sustavno identificiraju i koriste, pružajući vrijedne uvide za morske biologe i konzervatore.

RESULTS

DISCUSSION

APPENDIX

LITERATURA

- [1] ESFAHANIAN, Mahdi; ZHUANG, Hanqi; ERDOL, Nurgun. On contour-based classification of dolphin whistles by type. *Applied Acoustics*, 2014, 76: 274-279.
- [2] ZAKI, Ahmed Mohamed, et al. Predictive Analytics and Machine Learning in Direct Marketing for Anticipating Bank Term Deposit Subscriptions. *American Journal of Business and Operations Research*, 2024, 11.1: 79-88.
- [3] ZHANG, Ning, et al. Machine learning in screening high performance electrocatalysts for CO₂ reduction. *Small Methods*, 2021, 5.11: 2100987.
- [4] POULOSE, Alwin; HAN, Dong Seog. Hybrid deep learning model based indoor positioning using Wi-Fi RSSI heat maps for autonomous applications. *Electronics*, 2020, 10.1: 2.
- [5] SENGAR, Prateek P.; GAIKWAD, Mihir J.; NAGDIVE, Ashlesha S. Comparative study of machine learning algorithms for breast cancer prediction. In: *2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)*. IEEE, 2020. p. 796-801.
- [6] NUR KORKMAZ, Burla, et al. Automated detection of dolphin whistles with convolutional networks and transfer learning. *Frontiers in Artificial Intelligence*, 2023, 6: 1099022.