

# Praćenje sitnih objekata u toplinskim slikama

---

Štolfa, Duje

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://um.nsk.hr/um:nbn:hr:168:812234>

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 repository](#)



SVEUČILIŠTE U ZAGREBU  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1659

## **PRAĆENJE SITNIH OBJEKATA U TOPLINSKIM SLIKAMA**

Duje Štolfa

Zagreb, lipanj 2024.

SVEUČILIŠTE U ZAGREBU  
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1659

## **PRAĆENJE SITNIH OBJEKATA U TOPLINSKIM SLIKAMA**

Duje Štolfa

Zagreb, lipanj 2024.

## ZAVRŠNI ZADATAK br. 1659

Pristupnik: **Duje Štolfa (0036540976)**  
Studij: Elektrotehnika i informacijska tehnologija i Računarstvo  
Modul: Računarstvo  
Mentor: prof. dr. sc. Siniša Šegvić

Zadatak: **Praćenje sitnih objekata u toplinskim slikama**

### Opis zadatka:

Pronalaženje i praćenje objekata u videu važan je zadatak računalnog vida s mnogim zanimljivim primjenama. Ovaj rad razmatra praćenje aktivnosti ptica i šišmiša u toplinskim snimkama noćnog neba. U okviru rada, potrebno je upoznati biblioteke za rukovanje tenzorima i slikama. Proučiti i ukratko opisati postojeće pristupe za detekciju i praćenje sitnih objekata u slikama. Pribaviti snimke te oblikovati podskupove za validaciju i testiranje. Odabrati i prilagoditi prikladan postupak za promatranu primjenu te uhodati validiranje hiperparametara. Primijeniti naučene modele te prikazati i ocijeniti postignutu točnost. Procijeniti mogućnost raspoznavanja vrste objekata iz snimki. Predložiti pravce za budući rad. Radu priložiti izvorni i izvršni kod razvijenih postupaka, ispitne slijedove i rezultate, uz potrebna objašnjenja i dokumentaciju. Citirati korištenu literaturu i navesti dobivenu pomoć.

Rok za predaju rada: 14. lipnja 2024.

*Hvala!*

# Sadržaj

|  |           |
|--|-----------|
| <b>1. Uvod</b>                                       | <b>2</b>  |
| <b>2. Metode praćenja</b>                            | <b>4</b>  |
| 2.1. Prepoznavanje sitnih objekata                   | 4         |
| 2.1.1. Metoda VPS                                    | 4         |
| 2.1.2. Metoda KNN                                    | 7         |
| 2.2. Praćenje više objekata i pridruživanje podataka | 9         |
| 2.2.1. Rekurzivno filtriranje                        | 10        |
| 2.2.2. Ograđivanje i pridruživanje podataka          | 13        |
| 2.2.3. Upravljanje trajektorijama                    | 13        |
| <b>3. Eksperimenti</b>                               | <b>14</b> |
| 3.1. Skup podataka                                   | 14        |
| 3.2. Mjere vrednovanja                               | 16        |
| 3.2.1. Mjere nad oznakama u formatu MOT              | 16        |
| 3.2.2. Mjere nad grubim oznakama                     | 19        |
| 3.3. Postavke eksperimenata                          | 21        |
| 3.4. Eksperimenti na skupinama S1–S5                 | 22        |
| 3.5. Eksperimenti na snimkama V8 i V15               | 26        |
| <b>4. Zaključak</b>                                  | <b>30</b> |
| <b>Literatura</b>                                    | <b>32</b> |
| <b>Sažetak</b>                                       | <b>35</b> |
| <b>Abstract</b>                                      | <b>36</b> |

# 1. Uvod

Praćenje objekata uključuje prepoznavanje objekata u svakoj slici videa i njihovo međusobno razlikovanje kako bi se za pojedini objekt moglo odrediti gdje se nalazi u ostalim slikama snimke. Rješavanje ovih dvaju problema još je izazovnije kada su praćeni objekti vrlo mali i teško primjetni. U slučajevima gdje su objekti dovoljno veliki i fizičke značajke su im jasno razlučive, primjerice prilikom praćenja pješaka [1], pridruživanju podataka se tipično pristupa modeliranjem njihovog izgleda. Ovo nije primjenjivo na sitne objekte jer objektima čija površina iznosi samo nekoliko piksela značajke nisu vidljive i izgled im se može nekoliko puta tijekom snimke značajno promijeniti.

Problem računalnog prepoznavanja sitnih objekata nalazi primjene u pronalaženju anomalija u materijalima [2] ili greški nastalih u proizvodnji [3], pa čak i u prepoznavanju malih promjena u astronomskim slikama iznimno velikih rezolucija [4, 5]. U slučajevima gdje se ciljani objekti razlikuju u temperaturi od ostatka kadra, za snimanje se mogu koristiti termovizijske kamere koje pasivnim senzorom mjere razinu infracrvenog zračenja u sceni [6]. Ovo otvara mogućnosti primjene u područjima kao što su daljinska istraživanja [7], nadzor [8] i sigurnost [9].

Za ovaj je rad posebno zanimljiva primjena termovizijskih kamera u praćenju aktivnosti ptica i šišmiša u blizini vjetroelektrana. S obzirom da su sve vrste šišmiša u Hrvatskoj strogo zaštićene zakonom i da, između ostalog, jedinke u blizini vjetroagregata mogu završiti u vrtlogu zraka i stradati zbog barotraume [10] ili sudara s elisama, takav se monitoring provodi kako bi se utvrdila potreba za regulacijom rada elektrane i procijenio njen utjecaj na okoliš. Praćenje toplinskim kamerama posebno je važno za priobalne vjetroelektrane [11] koje su slabo dostupne i u kojima standardne metode kao što je prebrojavanje stradavanja pretraživanjem površine ispod vjetroagregata nisu primjenjive. Uočena je potreba za računalnom obradom takvih snimki zbog velike količine

podataka prikupljenih tijekom monitoringa i zahtjevnosti njihove analize.

Rad Betke i sur. [12] jedan je od prvih pristupa praćenju aktivnosti šišmiša koji se temelji na analizi termalnih snimki i računalnom vidu. S obzirom da je rad istraživao primjenu praćenja na prebrojavanje jedinki u velikoj koloniji šišmiša prilikom izlijetanja iz staništa, jedni njegovih od glavnih doprinosa su dvije metode pridruživanja podataka koje su dovoljno robusne i brze za istovremeno praćenje iznimno velikog broja jedinki. Također je predstavljen dinamički model pozadine i metoda za izdvajanje dijelova slike koji odstupaju od tog modela. Matzner i sur. [11] preuzima princip modeliranja pozadine iz tog rada, proširuje ga *video peak store* strukturama podatka i predstavljenu metodu koristi za praćenje malog broja jedinki u okolini priobalne vjetroelektrane. Glavni nedostatak te metode je eksplicitno postavljena donja granica na veličinu objekata koje je moguće s njom prepoznati.

U poglavlju 2. detaljno su opisane dvije metode za prepoznavanje sitnih objekata u toplinskim snimkama i njihova teorijska podloga. U nastavku tog poglavlja opisani su izazovi istovremenog praćenja više objekata te korištene metode za praćenje i pridruživanje podataka. Poglavlje 3. daje pregled provedenih eksperimenata i njihovih rezultata, kao i oblikovanog skupa podataka te korištenih mjera točnosti praćenja. Poglavlje 4. ukratko ponavlja najvažnije rezultate rada i daje prijedlog za buduća istraživanja.



## 2. Metode praćenja

### 2.1. Prepoznavanje sitnih objekata

Cilj ove faze praćenja je u svakoj slici videa izdvojiti dijelove na kojima se nalaze objekti koje želimo pratiti. Promotrimo li duži period snimanja u kojem se kamera ne pomiče, sitne jedinice koje u kratkom vremenskom rasponu prelijeću kroz scenu možemo smatrati anomalijama. Problem prepoznavanja objekata tada se svodi na modeliranje pozadine i računanje razine u kojoj se pojedina točka svake slike videa razlikuje od odabranog modela, odnosno na određivanje mjere anomalnosti svake točke. U daljnjem su tekstu opisana dva pristupa rješavanju tog problema.

#### 2.1.1. Metoda VPS

Metoda *video peak store* prepoznaje objekte istovremeno analizirajući više uzastopnih slika snimke, pri čemu se one učitavaju u grupama i spremaju u strukture podataka koje nazivamo prozorima. Svaki je prozor (kao i cijeli video) tenzor četvrtog reda i označavamo ga s  $\mathbf{I} \in \mathbb{X}_{\text{RGB}} = [0, 1]^{H \times W \times 3 \times T}$ . Kako u slučaju termalnih snimki temperatura neke točke može biti predstavljena intenzitetom topline  $i \in [0, 1]$  umjesto bojom (vektorom s RGB vrijednostima), prozori mogu biti i tenzori trećeg reda  $\mathbf{I} \in \mathbb{X} = [0, 1]^{H \times W \times T}$ . Ova je dva prikaza moguće razlikovati po redu tenzora i kroz rad će se za njih koristiti iste oznake.

Opisana metoda započinje učitavanjem dijela snimke u prozor za određivanje modela pozadine. Za svaku se sliku tog prozora računaju segmentacijske maske prema [12], u kojima se u drugom dijelu algoritma označavaju povezana područja. U posljednjem se koraku metode VPS prozor za određivanje modela pozadine dijeli na više manjih prozora koji se obrađuju postupkom iz [11] kako bi se iz prethodno izračunatih oznaka izdvojili

objekti od interesa. U nastavku su pobliže opisani dijelovi ovog postupka.

## Modeliranje pozadine

Pozadinu toplinske snimke modeliramo srednjom vrijednosti  $\mu$  i standardnom devijacijom  $\sigma$  intenziteta topline svake njene točke u određenom prozoru  $I$  duljine  $T$ :

$$\mu_{xy} = \frac{1}{T} \sum_{i=0}^T I_{xyi} \quad (2.1)$$

$$\sigma_{xy}^2 = \frac{1}{T} \sum_{i=0}^T (I_{xyi} - \mu_{xy})^2 \quad (2.2)$$

Anomalije su tada one točke prozora čiji intenzitet značajno odstupa od tog modela pozadine. Dijeljenjem snimke na pozadinske prozore model se prilagođava promjenama u pozadini do kojih može doći tijekom dugog snimanja. Ova je mogućnost prilagodbe modela posebice važna za toplinske snimke jer se, ovisno dijelu dana u kojem je snimanje obavljeno, a posebice po noći, temperatura okoline može brzo i drastično mijenjati.

Značajno odstupanje od modela pozadine u nekoj točki tog prozora moguće je definirati kao odstupanje od srednjeg intenziteta koje je veće od  $k$  standardnih devijacija. Pritom se u obzir uzimaju samo one točke na kojima je intenzitet veći od srednjeg jer su ptice i šišmiši koje želimo pratiti topliji od pozadine. Na taj se način za svaku sliku  $I_{xyt}$  u pozadinskom prozoru računa segmentacijska maska njenog prednjeg plana  $M_{xyt}$ .

$$M_{xyt} = \llbracket I_{xyt} > \mu_{xy} + k \cdot \sigma_{xy} \rrbracket = \begin{cases} 1, & I_{xyt} > \mu_{xy} + k \cdot \sigma_{xy} \\ 0, & \text{inače} \end{cases} \quad (2.3)$$

## Označavanje povezanih komponenti

Označavanje povezanih komponenti algoritam je kojim se dijelovi binarne maske  $\mathbf{M} \in \mathbb{Y}_M = [0, 1]^{W \times H \times T}$  koji nisu međusobno povezani označavaju različitim oznakama i kojim nastaju segmentacijske oznake  $\mathbf{S} \in \mathbb{Y}_S = \{1..C\}^{H \times W \times T}$ , gdje je  $C$  broj povezanih komponenti u slici. Povezanost pritom može biti definirana na razini 4-susjedstva ili 8-susjedstva. U 4-susjedstvu neke točke nalaze se one točke koje su izravno gore, do-

lje, lijevo ili desno od nje, a 8-susjedstvu pripadaju i one točke koje su joj dijagonalno susjedne. U metodi VPS ovaj se algoritam provodi nad segmentacijskim maskama  $\mathbf{M}$  koristeći 4-susjedstvo. U programskoj je potpori za označavanje povezanih komponenti korištena implementacija algoritma Spaghetti [13] iz knjižnice OpenCV, čiji je opis izvan dosega teme ovog rada.

## Izdvajanje prepoznatih objekata

Srž metode VPS čini ideja o pohranjivanju informacija o maksimalnim uočenim intenzitetima topline u svakoj točki kratkog dijela<sup>1</sup> toplinske snimke koji zovemo prozor VPS i označavamo s  $\tilde{I}$ . Sitni objekti u preletu znatno su većeg intenziteta od pozadine na kojoj se nalaze, pa očekujemo da će, ako je objekt preletio preko neke točke, njen intenzitet biti maksimalan upravo kada se objekt nalazi na njoj. U slici VPS spremljene su vrijednosti maksimalnih intenziteta iz prozora VPS:

$$\tilde{P}_{xy} = \max_t \tilde{I}_{xyt} \quad (2.4)$$

Ako u slici VPS označimo samo one točke čije vrijednosti značajno odstupaju od trenutnog modela pozadine, dobit ćemo masku VPS:

$$\tilde{M}_{xy} = \left[ \left[ \tilde{P}_{xy} > \mu_{xy} + k \cdot \sigma_{xy} \right] \right] \quad (2.5)$$

Iako su preleti u slikama VPS lako uočljivi, u njima nedostaje informacija o tome kojoj slici prozora pripada pojedini dio maske VPS. Matrica segmentacijskih jezgri  $\tilde{F}$  nastaje razdvajanjem maske VPS po slikama prozora VPS:

$$\tilde{F}_{xyt} = \left[ \left[ \arg \max_{t'} \tilde{I}_{xyt'} = t \right] \right] \quad (2.6)$$

U posljednjem se koraku metode VPS grade segmentacijske oznake prepoznatih objekata tako što se iz oznaka  $\mathbf{S}$  nastalih označavanjem povezanih komponenti u segmentacijskoj maski  $\mathbf{M}$  odabiru samo oni objekti koji se u barem jednoj točki sijeku s matricom segmentacijskih jezgri.

<sup>1</sup>Kao što je već natuknuto, više prozora VPS čini jedan pozadinski prozor i stoga su prozori VPS manji od pozadinskih.

## 2.1.2. Metoda KNN

Određivanje sličnosti među elementima nekog skupa podataka i pronalaženje podskupova najbližih elemenata (susjeda) nekom danom podatku jedan je pristup rješavanju klasifikacijskih i regresijskih problema. U slučaju kada su podatkovnom skupu pridružene oznake, razred podatka izvan tog skupa može se odrediti kao najčešći razred u skupu njemu najbližih susjeda, a za regresijske se probleme rezultat može računati interpolacijom oznaka u tom skupu susjeda.

Prepoznavanju anomalija često se pristupa kao nenadziranom problemu zato što su u stvarnim okruženjima anomalije rijetke i raznolike, a takve je podatke mahom i zahtjevno označavati [14]. Sustavi za nenadzirano prepoznavanje anomalija oslanjaju se na učenje onoga što anomalija nije (učenje na negativnim primjerima), umjesto učenja onoga što ona jest (pozitivni primjeri). Određivanjem sličnosti moguće je prepoznavati anomalije jer očekujemo da će pretraživanjem susjeda u skupu negativnih primjera udaljenost od susjeda biti znatno veća za podatke s anomalijama u odnosu na podatke bez njih.

Navedeni postupci temelje se na pretpostavci da udaljenost među podacima odražava njihova semantička obilježja, pa time i sličnost. Postupak kvantificiranja sličnosti ugradnjom podataka u niskodimenzionalni vektorski prostor na kojem udaljenost modelira sličnost izvornih podataka zove se metričko ugrađivanje [15, 16]. Sposobnost izlučivanja bitnih značajki iz podataka jedno je od ključnih svojstava dubokih neuronskih mreža, pa se metričko ugrađivanje najčešće rješavaju dubokim učenjem [17]. S obzirom da takvi modeli mogu raditi sa složenim podacima kao što su audiozapisi, slike, opisnici aktivnosti korisnika u nekoj aplikaciji i sl., određivanje sličnosti primjenjivo je na podatke iz raznih domena i provodi se neovisno o njoj, koristeći standardne mjere udaljenosti vektora koje zovemo metrikama.

**Definicija 1.** Za neprazni skup  $X$ , svako preslikavanje  $d : X \times X \rightarrow \mathbb{R}$  je **metrika** ako i samo ako zadovoljava sljedeće uvjete:

1.  $d(a, b) \geq 0 \quad \forall a, b \in X$  (pozitivnost)
2.  $d(a, b) = 0 \iff a = b \quad \forall a, b \in X$  (strogost)
3.  $d(a, b) = d(b, a) \quad \forall a, b \in X$  (simetričnost)

$$4. d(a, b) \leq d(a, c) + d(c, b) \quad \forall a, b, c \in X \quad (\text{nejednakost trokuta})$$

Tada je **metrički prostor** par  $(X, d)$ , a  $d(a, b)$  predstavlja generaliziranu udaljenost u skupu  $X$ , odnosno može se interpretirati kao udaljenost nekih njegovih elemenata  $a$  i  $b$ . Uređeni je par  $(\mathbb{R}^n, d_2)$  **n-dimenzionalan euklidski prostor**, a  $d_2$  **euklidska metrika**:

$$d_2(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad \mathbf{x}, \mathbf{y} \in \mathbb{R}^n \quad (2.7)$$

Iako je u ovom radu za određivanje sličnosti korištena samo euklidska metrika, važno je napomenuti da se u praksi često koriste i pseudometrike koje zadovoljavaju sve navedene uvjete osim strogosti. Takva je Mahalanobisova metrika kojom je moguće mjeriti udaljenost između vektora i skupine vektora koji pripadaju nekoj razdiobi vjerojatnosti.

Algoritam traženja  $k$  najbližih susjeda (engl. *k-nearest neighbours*, KNN) dio je predstavljene metode za prepoznavanje sitnih objekata u toplinskim snimkama. Kao i kod metode VPS, snimka se učitava u grupama od  $T$  uzastopnih slika i istovremeno se analiziraju sve slike tog prozora, a prepoznavanju se pristupa kao problemu prepoznavanja anomalija. Mjeru anomalnosti  $\delta$  definiramo na razini točke prozora  $I$  kao srednju udaljenost do njenih  $k$  najbližih susjeda u skupu svih točaka koje se nalaze u različitim slikama (tj. vremenima), ali na istim prostornim koordinatama kao i ona. Čak i u slučaju da je razina topline u svakoj točki predstavljena vektorom  $i_3 \in [0, 1]^3$  s RGB vrijednostima, nije potrebno provoditi metrička ugrađivanja već se udaljenost računa kao euklidska metrika u prostoru  $(\mathbb{R}^3, d_2)$ .

Iz izračunatih se mjera anomalnosti određuju segmentacijske maske postavljanjem praga  $\gamma \in \mathbb{R}^+$ . Točke čija je srednja udaljenost do  $k$  najbližih susjeda veća od zadanog praga klasificiraju se kao anomalije:

$$M_{xyt} = \llbracket \delta_{xyt} > \gamma \rrbracket \quad (2.8)$$

Za ostatak postupka praćenja potrebne su segmentacijske oznake  $\mathbf{S} \in \mathbb{Y}_S$  pa se nad maskom  $\mathbf{M}$  provodi postupak označavanja povezanih komponenti na način opisan u poglavlju 2.1.1.

## 2.2. Praćenje više objekata i pridruživanje podataka

Postupkom se praćenja iz mjerenja dobivenih promatranjem jednog ili više objekata oblikuju nizovi onih mjerenja koja odgovaraju istom objektu prepoznatom u različitim trenutcima snimke. Ove nizove zovemo trajektorijama. Mjerenje se pritom može shvatiti vrlo općenito kao prikupljanje bilo kakvih podataka o objektu kojeg želimo pratiti, primjerice, kao izlaz nekog konkretnog senzora ili rezultat obrade slike tog objekta, zbog čega se praćenje može primijeniti na širok raspon zadataka.

Neovisno o načinu mjerenja, osnovni se princip rada svakog sustava za praćenje temelji na procjeni budućih mjerenja iz onih do sada zabilježenih. Uzmimo za primjer mehanizam usmjeravanja radara prema jednom udaljenom objektu koji se brzo kreće. Kako se takvim sensorima mjerenja uobičajeno obavljaju u diskretnim intervalima, moguće je da objekt kojeg pratimo u tom vremenu izađe iz vidnog polja senzora. Ovo se sprječava usmjeravanjem radara prema mjestu na kojem očekujemo da će se objekt sljedeće nalaziti, odnosno računanjem projekcije budućeg položaja objekta iz dosadašnjih mjerenja. Nakon što sustav dobije podatak o stvarnom položaju objekta, projekcija se ispravlja i postupak se ponavlja.

Istovremeno praćenje više objekata (MTT, *multi-target tracking*) znatno je složeniji problem od prethodno opisanog problema praćenja jednog objekta (STT, *single-target tracking*) zato što, između ostalog, zahtijeva dodatan mehanizam kojim će se praćeni objekti međusobno razlikovati te pridruživati ispravnim trajektorijama. U stvarnim se okolnostima broj objekata koje je potrebno pratiti mijenja s vremenom jer objekti mogu u bilo kojem trenutku ući u vidno polje senzora ili izaći iz njega, što dodatno povećava složenost takvog sustava za praćenje.

Općeniti postupak praćenja više objekata može se podijeliti na faze filtriranja, ogradi-  
vanja, pridruživanja podataka i upravljanja trajektorijama koje se ciklički ponavljaju za svako mjerenje [18]. Prije mjerenja se za svaku trajektoriju procjenjuje stanje sljedećeg objekta u njoj, odnosno računaju se očekivani podaci koji bi trebali biti izmjereni kako bi bili pridruženi toj trajektoriji. Nakon što je mjerenje obavljeno, postojećim se trajektorijama pridružuju izmjereni podaci koji su najbliži odgovarajućoj projekciji. Kako se pritom udaljenost ne bi trebala računati za svaki par trajektorije i mjerenja, ograde izra-

čunate u prethodnoj iteraciji koriste se za grubi odabir onih mjerenja koje je razumno pridružiti određenoj trajektoriji. U fazi upravljanja trajektorijama preostala mjerenja koja nisu pridružena nijednoj trajektoriji postaju kandidati za početke novih trajektorija, a dio se postojećih trajektorija zaustavlja ili briše. Nad novim se skupom trajektorija ponovno provodi filtriranje i ograđivanje te se postupak ponavlja za nova mjerenja. Navedene faze pobliže su opisane u nastavku poglavlja.

### 2.2.1. Rekurzivno filtriranje

Filtriranje je proces procjene stvarnog stanja nekog sustava na temelju mjerenja pod utjecajem šuma. Najčešće korišteni takav algoritam je Kalmanov filtar i korišten je, primjerice, u misiji Apollo [19] kako bi se, unatoč nepreciznim instrumentima za određivanje položaja letjelice, kontinuiranim mjerenjem mogao pouzdano odrediti njen položaj i navigirati njom. Stanje sustava modelira se vektorom čije komponente najčešće odgovaraju fizičkim svojstvima sustava koje želimo pratiti, možemo izmjeriti ili izračunati. U slučaju procjene položaja letjelice Apollo, stanje je moglo biti modelirano položajem, brzinom, akceleracijom, orijentacijom letjelice i sl.

Rekurzivno filtriranje polazi od pretpostavke da stanje sustava u nekom trenutku ovisi samo o njegovom stanju u prethodnom trenutku [18]. Stoga je za dani trenutak moguće predvidjeti očekivano buduće stanje kako bismo ga tada mogli usporediti s izmjerenim veličinama i bolje procijeniti trenutno stanje sustava. Pritom točnost procijenjenog stanja ne ovisi samo o pouzdanosti mjerenja (mjerni šum), već i o tome koliko dobro model ovisnosti trenutnog stanja o prethodnom odgovara situaciji u stvarnom sustavu (procesni šum) [20].

U ovom je radu za procjenu lokacije objekata na termalnoj snimci korišten filtar  $\alpha$ - $\beta$  [18, 20] s četvorodimenzionalnim vektorom stanja

$$\mathbf{x}_n = \begin{bmatrix} x_n \\ y_n \\ \dot{x}_n \\ \dot{y}_n \end{bmatrix} \quad (2.9)$$

gdje su  $x_n$  i  $y_n$  koordinate težišta segmentacijske oznake tog objekta,  $\dot{x}_n$  i  $\dot{y}_n$  komponente

brzine tog težišta, a  $n$  redni broj slike u snimci (korak). Ako gibanje ptica i šišmiša modeliramo kao dvodimenzionalno gibanje konstantnom brzinom, na osnovu trenutnog stanja i vremenskog razmaka  $\Delta t$  između susjednih slika snimke možemo izračunati očekivano stanje u sljedećem koraku:

$$\begin{aligned}
 x_{n+1} &= x_n + \Delta t \cdot \dot{x}_n \\
 y_{n+1} &= y_n + \Delta t \cdot \dot{y}_n \\
 \dot{x}_{n+1} &= \dot{x}_n \\
 \dot{y}_{n+1} &= \dot{y}_n
 \end{aligned} \tag{2.10}$$

Ovaj sustav jednadžbi gibanja možemo zapisati u matričnom obliku.

$$\Phi = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{2.11}$$

$$\hat{\mathbf{x}}_{n+1,n} = \Phi \cdot \hat{\mathbf{x}}_{n,n} \tag{2.12}$$

Jednadžba (2.12) zove se jednadžba produkcije (engl. *state extrapolation equation*), a matrica  $\Phi$  je matrica prijelaza stanja. Oznake oblika  $\hat{\mathbf{x}}_{a,b}$  predstavljaju procjenu stanja u koraku  $a$  na osnovu stanja iz koraka  $b$ . Slučajevi u kojima je  $a = b$  označuju da je u procjenjenu vrijednost uračunato i mjerenje obavljeno u tom koraku. Konkretno,  $\hat{\mathbf{x}}_{n,n}$  je procjena stanja u koraku  $n$ , a  $\hat{\mathbf{x}}_{n+1,n}$  je procjena budućeg stanja na osnovu trenutne procjene stanja za korak  $n$ .

U općem slučaju stanje izravno ne odgovara mjerenim veličinama; neke se komponente stanja ne mogu mjeriti, a druge mogu odgovarati linearnoj kombinaciji više mjerenja. Kako bi se vektori stanja i mogli usporediti s vektorima mjerenja, potrebno ih je transformirati u odgovarajući oblik množenjem s matricom mjerenja  $\mathbf{H}$ . Za slučaj modeliranja sitnih objekata vektorom stanja u obliku (2.9) i pri čemu se brzine  $\dot{x}_n$  i  $\dot{y}_n$  ne



mogu izravno mjeriti, matrica mjerenja ima oblik

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (2.13)$$

Rezidual  $\mathbf{r}_n$  za korak  $n$  tada se računa kao odstupanje stvarnog mjerenja  $\mathbf{z}_n$  u tom koraku od vektora dobivenog transformacijom stanja predviđenog u koraku  $n - 1$ :

$$\mathbf{r}_n = \mathbf{z}_n - \mathbf{H} \cdot \hat{\mathbf{x}}_{n,n-1} \quad (2.14)$$

Jedan rekurzivni poziv algoritma za filtriranje završava računanjem procjene stanja za taj korak  $\hat{\mathbf{x}}_{n,n}$ . Ta vrijednost odgovara procjeni iz prethodnog koraka  $\hat{\mathbf{x}}_{n,n-1}$  ispravljenoj za  $\mathbf{K}_n \cdot \mathbf{r}_n$ :

$$\hat{\mathbf{x}}_{n,n} = \hat{\mathbf{x}}_{n,n-1} + \mathbf{K}_n \cdot (\mathbf{z}_n - \mathbf{H} \cdot \hat{\mathbf{x}}_{n,n-1}) \quad (2.15)$$

Jednadžba (2.15) je jednadžba korekcije stanja. Faktor  $\mathbf{K}_n$  zove se dobit filtra i određuje kompromis između procesnog i mjernog šuma. Veća dobit odgovara slučaju u kojem su mjerenja pouzdana, pa odstupanja predviđenih stanja od njih u konačnici trebaju imati veći utjecaj na procjenu stanja. U slučajevima kada jednadžba produkcije (2.12) dobro modelira stvarne mehanizme u sustavu, dobit je niska jer su tada veliki reziduali posljedica nepreciznosti mjerenja i ne bi trebali značajno utjecati na procjenu stanja. Razlikujemo filtre s nepromjenjivim dobitima i one kojima se dobit ispravlja nakon svakog rekurzivnog prolaza. Za razliku od Kalmanovog filtra, dobit filtra  $\alpha$ - $\beta$  nepromjenjiva je te ovisi o parametrima  $\alpha$  i  $\beta$ . Ove je parametre moguće interpretirati kao zasebne dobiti za komponente položaja odnosno brzine u vektoru stanja. Za vektor stanja u obliku (2.9), dobit filtra  $\alpha$ - $\beta$  je

$$\mathbf{K}_n = \begin{bmatrix} \alpha & 0 \\ 0 & \alpha \\ \frac{\beta}{\Delta t} & 0 \\ 0 & \frac{\beta}{\Delta t} \end{bmatrix} \quad (2.16)$$

Odabrane vrijednosti parametara  $\alpha$  i  $\beta$  za problem praćenja sitnih objekata navedene su i obrazložene u poglavlju 3.3.

## 2.2.2. Ograđivanje i pridruživanje podataka

Pri pridruživanju prepoznatih objekata nekoj trajektoriji razumno je ograničiti izbor objekata na podskup onih koji se nalaze unutar relativno malog područja oko kraja trajektorije. Ograđivanje (engl. *gating*) postupak je koji prethodi pridruživanju podataka i kojim se za svaku postojeću trajektoriju oko projiciranih položaja objekata određuje područje unutar kojeg se mogu nalaziti valjani kandidati za pridruživanje. U najjednostavnijem slučaju ta su područja pravokutnici ili krugovi fiksne veličine, a u složenijim slučajevima gdje korišteni filter računa mjeru pouzdanosti u točnost projiciranih stanja, ograde mogu biti omeđene elipsama čija je veličina određena tom kvalitetom predviđanja.

Iako se u optimalnom slučaju svakoj trajektoriji pridružuje po jedan najbliži objekt iz odgovarajućih ograda, konflikti su česta pojava u pridruživanju podataka i često se ne mogu jednoznačno razriješiti. Do konflikta može doći kada se dvije ograde preklapaju i u objema je isti objekt najbliži projiciranom položaju, pa je tada jednoj trajektoriji potrebno pridružiti objekt na suboptimalnom položaju. U ovom je radu korišten pohlepni pristup pridruživanju u kojem se prioritet daje dugo praćenim objektima [12]. Ovo je ostvareno slijednim dodjeljivanjem objekata od najdužih prema najkraćim trajektorijama, pri čemu se jednom pridruženi objekti ne uzimaju u obzir za daljnja pridruživanja.

## 2.2.3. Upravljanje trajektorijama

Mehanizmi za upravljanje prepoznatim trajektorijama [18] potrebni su jer se broj objekata u vidnom polju kamere mijenja s vremenom. Objekti koji u fazi pridruživanja nisu bili dodijeljeni nijednoj trajektoriji postaju početci novih, nepotvrđenih trajektorija. Kako vrlo kratke trajektorije mogu biti posljedica pogreški u prepoznavanju i kako bismo te pogreške mogli ublažiti, nepotvrđene trajektorije postaju aktivne tek kada im je dodijeljen određen broj prepoznatih objekata. Stoga aktivne trajektorije predstavljaju sve uspješno praćene objekte. Ako aktivnoj trajektoriji u posljednjih  $T$  slika snimke nije dodijeljen nijedan objekt, ona postaje neaktivna, odnosno smatra se da je praćeni objekt izašao iz scene. U slučaju da isto vrijedi za nepotvrđenu trajektoriju, ona se prekida i više joj se ne mogu pridruživati novi objekti.

## 3. Eksperimenti

Cilj eksperimentalnog dijela ovog rada usporediti je prethodno opisane metode na osnovi uspješnosti praćenja objekata te istražiti i opisati slučajeve u kojima su rezultati lošiji. Karakteristike korištenog skupa podataka navedene su u prvom dijelu poglavlja, nakon čega su opisane mjere po kojima su metode vrednovane kao i korištene vrijednosti parametara u eksperimentima. Predstavljeni su rezultati praćenja na većem skupu podataka koristeći mjere na razini prepoznavanja preleta, ali i rezultati na manjem skupu precizno označenih podataka u vidu najčešće korištenih mjera iz literature. Metode su implementirane u programskom jeziku Python koristeći biblioteke OpenCV, Faiss [15] i NumPy.<sup>1</sup>

### 3.1. Skup podataka

Eksperimenti su provedeni na 17 snimki rezolucije  $640 \times 480$  piksela, snimanih brzinom od 20 slika u sekundi. Podaci su prikupljeni tijekom praćenja faune šišmiša i ornitofaune na jednom vjetroparku, snimanjem pet različitih vjetroagregata termovizijskom kamerom pričvršćenom na stativ. Snimanje se odvijalo u sumrak tijekom četiri dana u ljetnim mjesecima i pri različitim atmosferskim uvjetima. Snimke traju između tri i sedam minuta, a snimane su u lažnoj boji s toplinskim paletama boja *red hot* i *rainbow*.

Toplinske snimke okarakterizirane su visokom razinom šuma što čak i ljudima otežava postupak prepoznavanja preleta prilikom označavanja podataka. Snimke su podijeljene u podskupove s niskom odnosno visokom razinom šuma. Kao mjera razine šuma korištena je ukupna varijacija (engl. *total variation*). Dok ukupna varijacija mjeri apsolutnu razliku između vremenski susjednih slika snimke i može se jednostavno izračunati na ovim podacima, mjere šuma koje se računaju uspoređujući slike sa šumom i

---

<sup>1</sup><https://github.com/DujeStolfa/ThermalVideoAnalysis.git>

bez njega (PSNR, SSIM, MSE) nisu prikladne za kvantifikaciju šuma u ovim podacima jer referentne slike bez šuma ne postoje. Srednja vrijednost ukupne varijacije za svaku snimku prikazana je u tablici 3.1. Za prag između niske i visoke razine šuma odabrana je vrijednost  $5 \cdot 10^6$ .

**Tablica 3.1.** Ukupna varijacija kao mjera šuma u svakoj snimci iz podatkovnog skupa. Podaci su podijeljeni u skupinu s niskom (gore) i visokom razinom šuma (dolje). Uz svaku je snimku naveden i broj preleta u stvarnim oznakama.

| <b>Snimka</b> | <b>Ukupna varijacija / <math>10^6</math></b> | <b>Broj preleta</b> |
|---------------|--|---------------------|
| V1            | 1.32   | 2                   |
| V2            | 1.35   | 1                   |
| V3            | 1.38   | 3                   |
| V4            | 1.65   | 1                   |
| V5            | 1.67   | 1                   |
| V6            | 1.67   | 1                   |
| V7            | 3.21   | 3                   |
| V8            | 3.27   | 1                   |
| V9            | 3.40   | 1                   |
| V10           | 3.54   | 6                   |
| V11           | 3.55   | 1                   |
| V12           | 3.90   | 16                  |
| V13           | 4.47   | 25                  |
| V14           | 4.50   | 37                  |
| V15           | 6.17   | 2                   |
| V16           | 6.21   | 4                   |
| V17           | 7.24   | 15                  |

Kako snimke nisu prikupljane u istim vremenskim uvjetima, moguće ih je dodatno kategorizirati ovisno o brzini zakretanja elisa snimljenog vjetroagregata. Tako razlikujemo snimke s neaktivnim, sporim i brzim vjetroagregatima. Elise neaktivnih vjetroagregata miruju tijekom cijele snimke, a kod sporih primjećujemo blage pomake tijekom barem jednog perioda od 30 sekundi. Elise brzog vjetroagregata u tom istom vremenu naprave barem jednu punu rotaciju.

Podaci su tako podijeljeni na ukupno pet skupina (tablice 3.2. i 3.3.) ovisno o razini šuma i stupnju aktivnosti vjetroagregata. Rezultati će biti promatrani po ovim skupinama kako bi se odredio utjecaj svake komponente na rezultate praćenja. S obzirom da sitni objekti mogu izgledati slično kao šum, robustna bi ih metoda trebala moći razlikovati. Također, zakretanje elisa, kao i svako kretanje koje ne želimo pratiti, dodatno

otežava problem praćenja i razumno je zasebno promotriti rezultate na takvim podacima.

**Tablica 3.2.** Skupovi podataka s obzirom na razinu šuma u snimkama i aktivnost snimljenog vjetroagregata.

|     |       | Aktivnost |      |     |
|-----|-------|-----------|------|-----|
|     |       | neaktivan | spor | brz |
| Šum | nizak | S1        | S3   | S5  |
|     | visok | S2        | S4   | -   |

**Tablica 3.3.** Popis snimki po skupovima iz tablice 3.2. Navedena je njihova ukupna duljina u minutama i ukupni broj preleta u stvarnim oznakama.

| Skupina | Snimke              | Broj preleta | Duljina |
|---------|---------------------|--------------|---------|
| S1      | V07,V08,V09,V10,V11 | 12           | 12:29   |
| S2      | V15,V16             | 6            | 08:30   |
| S3      | V01,V02,V03,V05     | 7            | 25:12   |
| S4      | V17                 | 15           | 06:03   |
| S5      | V04,V06,V12,V13,V14 | 80           | 34:53   |

U dvjema su snimkama (V10, V15) označeni preleti kako bi se uspješnost praćenja mogla evaluirati standardnim mjerama za praćenje objekata. Pritom je za svaku jedinku u svakoj slici prikupljen opisani pravokutnik, segmentacijska oznaka te njeno težište i površina. Oznake trajektorija spremljene su u formatu MOT [21], gdje je svakom opisanom pravokutniku pridružen identifikacijski broj jedinice i redni broj slike u kojoj se nalazi.

## 3.2. Mjere vrednovanja

Mjerenje točnosti praćenja uključuje određivanje u kojoj su mjeri objekti prepoznati i jesu li isti objekti u različitim slikama snimke ispravno pridruženi u trajektorije. U prvom dijelu ovog potpoglavlja opisane su mjere CLEARMOT [21], IDF1 [22] i HOTA [23] kao često korištene mjere za problem praćenja više objekata, dok je u drugom dijelu opisana prilagođena mjera iz [11] koja je prikladna za evaluaciju nad grubo označenim podacima.

### 3.2.1. Mjere nad oznakama u formatu MOT

Općeniti postupak računanja mjere točnosti praćenja započinje preslikavanjem (engl. *matching*) predviđenih oznaka u stvarne na osnovu mjere sličnosti i odgovarajućeg praga.

Mjera sličnosti određuje koliko je precizno prepoznati objekt lokaliziran i njen odabir ovisi o korištenim reprezentacijama oznaka. Jaccardov koeficijent prikladna je mjera sličnosti za metode koje koriste segmentacijske oznake i opisane pravokutnike, a općenito predstavlja omjer presjeka i unije neka dva skupa.

$$\text{IoU} = \frac{|\text{TP}|}{|\text{TP}| + |\text{FN}| + |\text{FP}|} \quad (3.1)$$

## MOTA

Mjera MOTA (*Multiple Object Tracking Accuracy*) najčešće je korištena mjera za problem praćenja objekata [23]. Bijektivnim preslikavanjem na razini pojedinačnih objekata oblikuje se skup svih prepoznatih objekata koji se ne mogu preslikati ni u jednu stvarnu oznaku (skup FP) i skup stvarnih oznaka bez odgovarajuće predviđene oznake (skup FN). Preslikati se mogu one oznake za koje je mjera sličnosti  $S$  veća ili jednaka lokalizacijskom pragu  $\alpha$ . U slučaju da se stvarne i predviđene oznake mogu preslikati na više načina, odabire se preslikavanje koje maksimizira vrijednost MOTA.

Kako bi se u konačnu vrijednost mjere uračunala točnost pridruživanja (engl. *association accuracy*) objekata trajektorijama, oblikuje se skup promjena identifikatora IDSW (*Identity Switch*) kao podskup točno prepoznatih objekata (TP) čiji se identifikator razlikuje od identifikatora prethodnog objekta u istoj stvarnoj trajektoriji.

Mjera MOTA računa se prema izrazu (3.2) i poprima vrijednosti iz skupa  $\langle -\infty, 1 \rangle$ . Mjera je najveća kada nema pogreški u vidu lažnih pozitiva i negativa te promjena identifikatora, a negativna je kada ukupan broj tih greški nadmašuje broj objekata u stvarnim oznakama (GT).

$$\text{MOTA} = 1 - \frac{|\text{FN}| + |\text{FP}| + |\text{IDSW}|}{|\text{GT}|} \quad (3.2)$$

## MOTP

Kako u mjeru MOTA nije uračunata preciznost pri lokalizaciji objekata, mjera MOTP (*Multiple Object Tracking Precision*) koristi se kao mjera točnosti lokalizacije objekata, a računa se kao srednja vrijednost mjere sličnosti  $S$  kroz sve točno prepoznate objekte.

$$\text{MOTP} = \frac{1}{|\text{TP}|} \sum_{\text{TP}} \mathcal{S} \quad (3.3)$$

## IDF1

Za razliku od mjere MOTA, preslikavanje se za mjeru IDF1 odvija na razini cijelih trajektorija. Dijelovi prepoznatih trajektorija koji se značajno preklapaju sa stvarnim trajektorijama oblikuju skup IDTP, dok skupove IDFN i IDFP čine preostali objekti iz stvarnih odnosno prepoznatih trajektorija. Ta se mjera računa kao harmonijska sredina preciznosti i odziva na razini trajektorije, a od mogućih preslikavanja odabire se ono za koje će mjera IDF1 biti najveća.

$$\text{IDF1} = \frac{|\text{IDTP}|}{|\text{IDTP}| + 0.5 |\text{IDFN}| + 0.5 |\text{IDFP}|} \quad (3.4)$$

## HOTA

Kako su mjere MOTA i IDF1 pristrane su prema točnosti prepoznavanja odnosno pridruživanja, mjera HOTA uvedena je s ciljem ravnopravnog vrednovanja prepoznavanja, pridruživanja i lokalizacije [23]. Prilikom računanja mjere HOTA koriste se skupovi TP, FP i FN nastali bijektivnim preslikavanjem na razini objekta na određenom lokalizacijskom pragu. Također se oblikuju skupovi stvarno pozitivnih pridruženih parova (TPA, *true positive associations*), kao i lažno negativnih (FNA, *false negative associations*) te lažno pozitivnih pridruženih parova (FPA, *false positive associations*). Ovi su skupovi definirani u odnosu na jedan element  $c \in \text{TP}$  i za određeni prag  $\alpha$  mjere sličnosti  $\mathcal{S}$ , a mjera pridruživanja  $\mathcal{A}$  Jaccardov je koeficijent izračunat pomoću njih.

$$\mathcal{A}(c) = \frac{|\text{TPA}(c)|}{|\text{TPA}(c)| + |\text{FNA}(c)| + |\text{FPA}(c)|} \quad (3.5)$$

Točnost pridruživanja za određeni lokalizacijski prag  $\alpha$  mjera je pridruživanja usrednjena po svim  $c \in \text{TP}$ , a odgovarajuća se točnost prepoznavanja računa kao Jaccardov koeficijent nad skupovima TP, FP i FN.

$$\text{AssA}_\alpha = \frac{1}{|\text{TP}|} \sum_{c \in \text{TP}} \mathcal{A}(c) \quad (3.6)$$

$$\text{DetA}_\alpha = \frac{|\text{TP}|}{|\text{TP}| + |\text{FN}| + |\text{FP}|} \quad (3.7)$$

Mjera HOTA za fiksni lokalizacijski prag  $\alpha$  geometrijska je sredina točnosti pridruživanja i točnosti prepoznavanja. U konačnu mjeru HOTA uračunata je lokalizacijska točnost integriranjem po (diskretnim) pragovima  $\alpha$ . Greške pri lokalizaciji mjere se neovisno o svim prethodno navedenim mjerama i izražene su mjerom LocA.

$$\text{HOTA}_\alpha = \sqrt{\text{DetA}_\alpha \cdot \text{AssA}_\alpha} \quad (3.8)$$

$$\begin{aligned} \text{HOTA} &= \int_0^1 \text{HOTA}_\alpha d\alpha \\ &\approx \frac{1}{19} \sum_{\alpha \in \{0.05, 0.1, \dots, 0.95\}} \text{HOTA}_\alpha \end{aligned} \quad (3.9)$$

### 3.2.2. Mjere nad grubim oznakama

Zbog vremenske zahtjevnosti prikupljanja segmentacijskih oznaka na velikom skupu podataka, dio eksperimenata evaluiran je pomoću validacijskih mjera iz [11] koje se ne moraju strojno računati, već ih može računati anotator usporedbom grubih oznaka preleta<sup>2</sup> s iscrtanim rezultatima praćenja. Korištene oznake nisu strogo strukturirane, ali su dovoljno informativne da anotator pomoću njih može znati kada se i gdje u snimci dogodio prelet te koji je bio smjer kretanja jedinke.

Problem praćenja preleta ptica i šišmiša takav je da točnost pridruživanja i lokalizacije imaju znatno manju važnost od ukupnog odziva na razini preleta. Drugim riječima, relevantna mjera visoke razine za kontekst monitoringa okoliša mora dobro mjeriti broj uspješno prepoznatih preleta. Zbog ovog je korišten prag za prepoznavanje takav da maksimizira odziv. Tako je svaki prelet iz stvarnih oznaka označen kao prepoznat ako

<sup>2</sup>Kako bi se jasno razlikovali nizovi istih objekata (trajektorije) u stvarnim i predviđenim oznakama, stvarne se trajektorije naziva preletima.



postoji barem jedna prepoznata trajektorija koja se s njime preklapa u barem dva uzastopna objekta. Pritom se zbog nepreciznih oznaka uvjet preklapanja ne može egzaktno odrediti, već ga anotator određuje subjektivno.

Popis svih korištenih mjera na razini preleta i njihovih opisa prikazan je tablicom 3.4. U tablici 3.5. navedene su formule po kojima su izračunate mjere izvedene preko drugih mjera.

**Tablica 3.4.** Mjere za validaciju praćenja na grubo označenim podacima. U gornjem su dijelu tablice opisane mjere koje su se pri evaluaciji izravno mjerile, a mjere iz donjeg dijela tablice računale su se prema tablici 3.5.

| <b>Mjera</b>                         | <b>Opis</b>   |
|--------------------------------------|---|
| <b>Ukupno preleta</b>                | broj preleta u stvarnim oznakama                                  |
| <b>Prepoznati preleti</b>            | broj točno prepoznatih preleta                                    |
| <b>Ukupno trajektorija</b>           | broj različitih trajektorija u prepoznatim oznakama               |
| <b>Točno prepoznate trajektorije</b> | broj trajektorija koje se mogu povezati s jednim preletom         |
| <b>Lažni pozitivivi</b>              | broj prepoznatih trajektorija koje ne odgovaraju nijednom preletu |
| <b>Lažna razdvajanja</b>             | broj prekida u točno prepoznatim trajektorijama                   |
| <b>Odziv</b>                         | udio prepoznatih preleta u skupu stvarnih oznaka                  |
| <b>Stopa lažnih pozitiviva</b>       | udio lažnih pozitiviva u skupu prepoznatih oznaka                 |
| <b>Stopa lažnog razdvajanja</b>      | broj prekida po prepoznatom preletu                               |

**Tablica 3.5.** Izrazi za računanje mjera nad grubim oznakama iz donjeg dijela tablice 3.4.

| <b>Mjera</b>             | <b>Formula</b>   |
|--------------------------|--|
| Lažni pozitivivi         | $ukupno\ trajektorija - točno\ prepoznate\ trajektorije$   |
| Lažna razdvajanja        | $točno\ prepoznate\ trajektorije - prepoznati\ preleti$    |
| Odziv                    | $\frac{prepoznati\ preleti}{ukupno\ preleta} \cdot 100$    |
| Stopa lažnih pozitiviva  | $\frac{lažni\ pozitivivi}{ukupno\ trajektorija} \cdot 100$ |
| Stopa lažnog razdvajanja | $\frac{lažna\ razdvajanja}{prepoznati\ preleti}$           |

### 3.3. Postavke eksperimenata

Eksperimenti su provedeni na svim snimkama u skupu podataka (V1-V17) koristeći metode VPS i KNN za prepoznavanje te  $\alpha$ - $\beta$  filtar za praćenje. Predviđene oznake spremljene su u MOT formatu i naknadno su iscrtane na snimkama.

Korišteni parametri za prepoznavanje prikazani su tablicama 3.6. i 3.7. Za metodu KNN odabrano je šest pragova mjere anomalnosti i praćenje je provedeno zasebno za svaki prag. Veličine prozora za obje metode ograničene su dostupnom radnom memorijom procesora na kojem se provode eksperimenti i očekivanim trajanjem preleta te su njihove vrijednosti odabrane shodno tome.

**Tablica 3.6.** Postavke metode KNN za prepoznavanje objekata.

| Parametar                   | Vrijednost                         |
|-----------------------------|------------------------------------|
| veličina prozora za analizu | 128 slika                          |
| prag mjere anomalnosti      | {600, 800, 1200, 1600, 2000, 2400} |
| k                           | 16                                 |

**Tablica 3.7.** Postavke metode VPS za prepoznavanje objekata.

| Parametar                                     | Vrijednost       |
|---|------------------|
| veličina VPS prozora                          | 128 slika        |
| veličina prozora za računanje modela pozadine | 1024 slika       |
| maksimalan broj prepoznatih objekata po slici | 8                |
| prag za prepoznavanje                         | $8 \cdot \sigma$ |

Tablica 3.8. prikazuje parametre sustava za praćenje. Kako se kroz početna istraživanja pokazalo da metoda VPS prepoznaže znatno više lažno pozitivnih objekata od metode KNN, za eksperimente koji koriste metodu VPS korišten je trostruko manji polumjer vrata. Vrijednosti  $\alpha$  i  $\beta$  ovise o preciznosti mjerenja, odnosno točnosti metode za prepoznavanje. Očekivano je da će obje metode vrlo pouzdano lokalizirati objekte, ali da će se njihova brzina tijekom preleta moći naglo mijenjati, stoga su za parametre  $\alpha$  i  $\beta$  odabrane relativno visoke odnosno niske vrijednosti.

Usporedbom grubih oznaka i iscrtanih trajektorija izračunate su mjere na razini preleta na cijelom skupu podataka i za obje metode prepoznavanja objekata. Za računanje mjera HOTA, MOTA, MOTP i IDF1 korišten je sustav TrackEval [24].

**Tablica 3.8.** Postavke algoritma za praćenje objekata.

| <b>Parametar</b>   | <b>Vrijednost</b>          |
|--|----------------------------|
| $\alpha$   | 0.95                       |
| $\beta$  | 0.3                        |
| najmanja duljina potvrđene trajektorije                          | 3 slike                    |
| najveći vremenski razmak između dva objekta u istoj trajektoriji | 3 slike                    |
| polumjer vrata za prepoznavanje                                  | 20 px (VPS)<br>60 px (KNN) |

### 3.4. Eksperimenti na skupinama S1–S5

Tablicama 3.9.–3.13. prikazani su rezultati praćenja korištenjem metode KNN na skupinama S1-S5 koji uspoređuju uspješnost praćenja za različite pragove mjere anomalnosti. Uočavamo da odziv i broj točno prepoznatih trajektorija padaju s porastom praga anomalnosti kroz sve skupine, što je očekivano s obzirom da taj prag izravno određuje koji će dijelovi slike biti prepoznati kao objekti i koji će u konačnici biti pridruženi u trajektorije. Stope lažnog razdvajanja su niske ( $< 4$ ) kroz sve skupine i ne pokazuju izravnu ovisnost o odabranom pragu.

Najveći odziv među svim pragovima i skupinama ostvaren je na podacima iz skupine S3 (tablica 3.11.) pri najnižim pragovima 600 i 800. Pritom je stopa lažnih pozitiva, iako vrlo visoka (91.6 % i 92.4 %), usporediva s prosjekom među svim skupinama, a broj lažno pozitivnih trajektorija znatno niži od svih ostalih skupina. Ovi rezultati pokazuju da metoda KNN može pružiti zadovoljavajuće rezultate unatoč sporim pomacima elisa vjetroagregata. Na istim je podacima ostvaren i sveukupno najmanji odziv (14.3 %) što nam ukazuje da izbor praga mjere anomalnosti može drastično utjecati na rezultate praćenja.

Može se primijetiti da broj lažnih pozitiva raste s porastom praga mjere anomalnosti u svim skupinama, ali iznos te promjene ovisi o pojedinoj skupini. Tako je na podacima iz S4 (tablica 3.12.) broj lažnih pozitiva na najnižem pragu čak više od 1500 puta veći od broja lažnih pozitiva na najvišem pragu, dok taj isti omjer na S5 (tablica 3.13.) iznosi tek 2.4. Mala promjena broja lažnih pozitiva na snimkama skupine S5 posljedica je velike brzine zakretanja elisa i ukazuje na to da odabir praga u metodi KNN ne može znatno poboljšati preciznost na takvim podacima.

S obzirom da snimke iz skupine S4 imaju visoku razinu šuma i nisku brzinu zakretanja elisa, spomenuta drastična promjena broja lažnih pozitiva govori u prilog hipotezi da metoda KNN uspješno zanemaruje spore pomake elisa. Naime, iako je očekivano da će visoki šum proizvesti veliki broj lažnih pozitiva (kao kod rezultata na S2), utjecaj tog šuma može biti otklonjen postavljanjem visokog praga mjere anomalnosti. Smanjenjem šuma, zakretanje elisa jedina je preostala komponenta koja može biti uzrok vrlo velikom broju lažnih pozitiva. Na rezultatima iz S4 vidimo da je upravo u tom slučaju broj lažnih pozitiva iznimno nizak, a odgovarajuća je stopa lažnih pozitiva (75 %) čak najmanja među svim skupinama.

U istim su tablicama za svaku skupinu označeni pragovi mjere anomalnosti koji se koriste za daljnju usporedbu s metodom VPS. Prilikom odabira praga najveća je važnost dodijeljena visokom odzivu, a zatim niskom broju lažno pozitivnih trajektorija. Gdje je to bilo moguće, odabran je prag za koji će odziv biti veći od 50 %, a da je pritom broj lažnih pozitiva manji od 1000. Odabrani se pragovi međusobno razlikuju i možemo primijetiti da optimalan prag u jednoj skupini, primjerice 1600 u skupini S4, može u drugim skupinama dati vrlo loše rezultate. Ovo ukazuje na izazovnost odabira optimalnog praga u metodi KNN.

**Tablica 3.9.** Točnost prepoznavanja preleta metodom KNN na podacima iz skupine S1 kroz različite razine praga mjere anomalnosti. U stvarnim je oznakama skupine S1 zabilježeno ukupno 12 preleta.

| Prag       | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivni | Odziv       | Stopa lažnih pozitiva | Stopa razdvajanja |
|------------|--------------------|--------------------------|-----------------|-------------|-----------------------|-------------------|
| <b>600</b> | 7                  | 25                       | 750             | <b>58.3</b> | 96.8                  | 2.6               |
| 800        | 6                  | 19                       | 390             | 50.0        | 95.4                  | 2.2               |
| 1200       | 6                  | 19                       | 218             | 50.0        | 92.0                  | 2.2               |
| 1600       | 6                  | 16                       | 182             | 50.0        | 91.9                  | <b>1.7</b>        |
| 2000       | 5                  | 16                       | 144             | 41.7        | 90.0                  | 2.2               |
| 2400       | 5                  | 17                       | 126             | 41.7        | <b>88.1</b>           | 2.4               |

Tablica 3.14. uspoređuje metode VPS i KNN na podatkovnim skupovima S1-S5. Promatrajući odziv, metoda VPS nadmašuje metodu KNN na podacima s niskom razinom šuma (S1, S3 i S5) i na njima ostvaruje znatno bolje rezultate nego na ostalim podacima. Pritom je broj lažnih pozitiva za obje metode iznimno visok na S5 zbog brzog zakretanja elisa vjetroagregata, a na podacima sa sporim zakretanjem elisa (S3) metoda KNN pre-

**Tablica 3.10.** Točnost metode KNN na podacima iz skupine S2. U stvarnim je oznakama te skupine zabilježeno ukupno 6 preleta.

| Prag       | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivivi | Odziv       | Stopa lažnih pozitiviva | Stopa razdvajanja |
|------------|--------------------|--------------------------|------------------|-------------|-------------------------|-------------------|
| <b>600</b> | 4                  | 8                        | 84788            | <b>66.7</b> | 100.0                   | <b>1.0</b>        |
| 800        | 3                  | 9                        | 44169            | 50.0        | 100.0                   | 2.0               |
| 1200       | 2                  | 6                        | 17544            | 33.3        | 100.0                   | 2.0               |
| 1600       | 2                  | 6                        | 9056             | 33.3        | 99.9                    | 2.0               |
| 2000       | 2                  | 7                        | 5204             | 33.3        | 99.9                    | 2.5               |
| 2400       | 2                  | 6                        | 2896             | 33.3        | <b>99.8</b>             | 2.0               |

**Tablica 3.11.** Točnost metode KNN na podacima iz skupine S3. U stvarnim je oznakama te skupine zabilježeno ukupno 7 preleta.

| Prag       | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivivi | Odziv       | Stopa lažnih pozitiviva | Stopa razdvajanja |
|------------|--------------------|--------------------------|------------------|-------------|-------------------------|-------------------|
| 600        | 5                  | 24                       | 262              | <b>71.4</b> | 91.6                    | 3.8               |
| <b>800</b> | 5                  | 14                       | 171              | <b>71.4</b> | 92.4                    | 1.8               |
| 1200       | 3                  | 8                        | 52               | 42.9        | 86.7                    | 1.7               |
| 1600       | 2                  | 5                        | 12               | 28.6        | 70.6                    | 1.5               |
| 2000       | 2                  | 4                        | 6                | 28.6        | <b>60.0</b>             | 1.0               |
| 2400       | 1                  | 1                        | 4                | 14.3        | 80.0                    | <b>0.0</b>        |

**Tablica 3.12.** Točnost metode KNN na podacima iz skupine S4. U stvarnim je oznakama te skupine zabilježeno ukupno 15 preleta.

| Prag        | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivivi | Odziv       | Stopa lažnih pozitiviva | Stopa razdvajanja |
|-------------|--------------------|--------------------------|------------------|-------------|-------------------------|-------------------|
| 600         | 8                  | 17                       | 27880            | <b>53.3</b> | 99.9                    | 1.1               |
| 800         | 8                  | 17                       | 10766            | <b>53.3</b> | 99.8                    | 1.1               |
| 1200        | 7                  | 15                       | 1456             | 46.7        | 99.0                    | 1.1               |
| <b>1600</b> | 7                  | 12                       | 326              | 46.7        | 96.4                    | 0.7               |
| 2000        | 5                  | 7                        | 76               | 33.3        | 91.6                    | <b>0.4</b>        |
| 2400        | 4                  | 6                        | 18               | 26.7        | <b>75.0</b>             | 0.5               |

**Tablica 3.13.** Točnost metode KNN na podacima iz skupine S5. U stvarnim je oznakama te skupine zabilježeno ukupno 80 preleta.

| Prag       | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivni | Odziv       | Stopa lažnih pozitivna | Stopa razdvajanja |
|------------|--------------------|--------------------------|-----------------|-------------|------------------------|-------------------|
| <b>600</b> | 42                 | 108                      | 104664          | <b>52.5</b> | 99.9                   | 1.6               |
| 800        | 33                 | 102                      | 84855           | 41.3        | 99.9                   | 2.1               |
| 1200       | 27                 | 62                       | 65962           | 33.8        | 99.9                   | 1.3               |
| 1600       | 23                 | 53                       | 54470           | 28.8        | 99.9                   | 1.3               |
| 2000       | 17                 | 36                       | 47854           | 21.3        | 99.9                   | <b>1.1</b>        |
| 2400       | 13                 | 37                       | 43677           | 16.3        | 99.9                   | 1.8               |

poznaje čak 11 puta manje lažno pozitivnih trajektorija od metode VPS. Metoda KNN ima uvjerljivo nižu stopu lažnog razdvajanja od metode VPS na svim skupinama osim S4.

**Tablica 3.14.** Usporedba točnosti prepoznavanja preleta metodama VPS i KNN. Za metodu KNN korišteni su pragovi mjere anomalnosti koji daju najbolje rezultate u pojedinoj skupini.

| Skupina | Metoda | Prepoznati preleti | Točno prepoznati preleti | Lažni pozitivni | Odziv        | Stopa lažnih pozitivna | Stopa razdvajanja |
|---------|--------|--------------------|--------------------------|-----------------|--------------|------------------------|-------------------|
| S1      | VPS    | 9                  | 49                       | 39              | <b>75.0</b>  | <b>44.3</b>            | 4.4               |
|         | KNN    | 7                  | 25                       | 750             | 58.3         | 96.8                   | <b>2.6</b>        |
| S2      | VPS    | 2                  | 16                       | 2018            | 33.3         | <b>99.2</b>            | 7.0               |
|         | KNN    | 4                  | 8                        | 84788           | <b>66.7</b>  | 100.0                  | <b>1.0</b>        |
| S3      | VPS    | 7                  | 63                       | 1960            | <b>100.0</b> | 96.9                   | 8.0               |
|         | KNN    | 5                  | 14                       | 171             | 71.4         | <b>92.4</b>            | <b>1.8</b>        |
| S4      | VPS    | 6                  | 8                        | 2               | 40.0         | <b>20.0</b>            | <b>0.3</b>        |
|         | KNN    | 7                  | 12                       | 326             | <b>46.7</b>  | 96.4                   | 0.7               |
| S5      | VPS    | 53                 | 231                      | 21469           | <b>66.3</b>  | <b>98.9</b>            | 3.4               |
|         | KNN    | 42                 | 108                      | 104664          | 52.5         | 99.9                   | <b>1.6</b>        |

Usporedimo li međusobno rezultate na podacima s visokom razinom šuma (S2 i S4), primijetit ćemo da obje metode na skupini S4 ostvaruju iznenađujuće nizak broj lažnih pozitivna, pogotovo kada u obzir uzmemo činjenicu da snimka iz skupine S4 (V17) ima veću ukupnu varijaciju od snimki iz skupine S2 (V15, V16). Ovi naizgled neintuitivni rezultati posljedica su ograničenja ukupne varijacije kao mjere šuma i razlike u temperaturi zraka<sup>3</sup> prilikom snimanja tih dviju skupina. Naime, na snimkama V15 i V16 po-

<sup>3</sup>Važno je napomenuti da je do prividne razlike u temperaturi moglo doći zbog različitog podešavanja termovizijske kamere prilikom snimanja.

druže više temperature (nijanse zelene boje na slici 3.1.a) veće je površine od područja slične temperature na snimci V17 (slika 3.1.b). Šum je upravo na tim područjima najizraženiji i ima veći utjecaj na rezultate od šuma na hladnijim dijelovima snimke. Drugim riječima, iako obje metode na snimkama skupine S2 prepoznaju svijetli šum na zelenoj pozadini (crveni kvadrat na slici 3.1.a) kao lažne pozitivne, to nije slučaj za snimku V17 jer na njoj takav šum nije prisutan. Ovi rezultati ukazuju na to (i) da postoje različite vrste šuma koje imaju različit utjecaj na točnost praćenja, (ii) da ukupna varijacija samostalno ne pruža iscrpni opis šuma te (iii) da bi podrobnija analiza utjecaja šuma na rezultate praćenja zahtijevala istovremeno korištenje različitih mjera razine šuma.


### 3.5. Eksperimenti na snimkama V8 i V15

Rezultati praćenja metodom KNN na snimkama V8 i V15 prikazani su tablicama 3.15. i 3.16. Rezultati na snimci V15 lošiji su od rezultata na V8 po svim mjerama osim MOTP. Relativno visoke vrijednosti mjere MOTP na objema snimkama ukazuju samo na to da metoda KNN točno prepoznate objekte može dobro lokalizirati i ne daju nam nikakvu informaciju o točnosti praćenja. Sve su vrijednosti MOTA negativne, što ukazuje na iznimno velik broj lažno pozitivnih objekata, posebice na snimci V15 na kojoj ta mjera doseže vrijednost od  $-8.34 \cdot 10^5$ . Kako je IDF1 jedina prikazana mjera koja bijektivno povezivanje stvarnih i prepoznatih oznaka radi na razini trajektorija, niske vrijednosti te mjere na V15 ukazuju da je na tim rezultatima teško ostvariti takvo povezivanje.


**Tablica 3.15.** Usporedba različitih mjera točnosti praćenja objekata na snimci V8 koristeći metodu KNN.

| Prag       | HOTA       | DetA       | AssA        | MOTA          | MOTP        | IDF1        |
|------------|------------|------------|-------------|---------------|-------------|-------------|
| 600        | 6.4        | 3.1        | <b>13.2</b> | -767.5        | <b>64.8</b> | 2.75        |
| <b>800</b> | <b>6.8</b> | 3.8        | 12.7        | -459.2        | 63.5        | <b>2.82</b> |
| 1200       | 5.8        | <b>3.9</b> | 9.1         | -273.7        | 59.8        | 1.84        |
| 1600       | 5.6        | 3.6        | 9.4         | -190.6        | 59.4        | 1.33        |
| 2000       | 4.7        | 3.1        | 7.3         | -141.6        | 57.0        | 0.96        |
| 2400       | 4.1        | 2.7        | 6.9         | <b>-124.3</b> | 56.2        | 0.35        |

Mjera HOTA i njene komponente informativnije su od ostalih mjera i pružaju bolji uvid u točnost rezultata. Promotrimo li tako rezultate na snimci V8, primijetit ćemo da je točnost prepoznavanja stabilna kroz sve pragove, a da točnost pridruživanja opada s povećanjem praga. Na snimci V15 događa se suprotno; točnost pridruživanja oscilira



(a) Slika iz snimke V16. Metode KNN i VPS u donjem dijelu kadra prepoznaju lažne pozitive.



(b) Slika iz snimke V17 uhvaćena tijekom preleta šišmiša (zeleni kvadrat).

**Slika 3.1.** Isječci snimki iz skupine S2 (3.1.a) i S4 (3.1.b). Iznimno velik broj lažnih pozitiva u rezultatima na skupini S2 posljedica je intenzivnog šuma. To se ne događa na podacima iz skupine S4 (crveni kvadrat na slici 3.1.b) jer je šum na snimkama iz S2 (crveni kvadrat na slici 3.1.a) većeg intenziteta i percepcijski je sličan jedinci koju želimo prepoznati (zeleni kvadrat).



**Tablica 3.16.** Usporedba različitih mjera točnosti praćenja objekata na snimci V15 koristeći metodu KNN.

| <b>Prag</b> | <b>HOTA</b> | <b>DetA</b>  | <b>AssA</b> | <b>MOTA</b>                         | <b>MOTP</b> | <b>IDF1</b>  |
|-------------|-------------|--------------|-------------|-------------------------------------|-------------|--------------|
| 600         | 0.3         | 0.009        | 11.4        | $-8.3 \cdot 10^5$                   | <b>78.5</b> | 0.006        |
| 800         | 0.5         | 0.016        | <b>14.5</b> | $-4.0 \cdot 10^5$                   | 76.9        | 0.012        |
| 1200        | 0.8         | 0.047        | 13.5        | $-1.3 \cdot 10^5$                   | 71.4        | 0.033        |
| 1600        | 1.2         | 0.099        | 14.0        | $-5.0 \cdot 10^4$                   | 67.4        | 0.092        |
| 2000        | 1.8         | 0.228        | 13.7        | $-2.1 \cdot 10^4$                   | 69.9        | 0.122        |
| <b>2400</b> | <b>2.3</b>  | <b>0.464</b> | 11.4        | <b><math>-9.1 \cdot 10^3</math></b> | 66.5        | <b>0.247</b> |

oko određene vrijednosti, dok se točnost prepoznavanja monotono povećava s porastom praga. Dakle, odabir praga mjere anomalnosti može različito utjecati na točnosti pridruživanja i prepoznavanja te se taj utjecaj može razlikovati od snimke do snimke. Kao što smo naslutili iz niske mjere MOTA, metoda KNN na snimci V15 ostvaruje loše rezultate zbog izrazito niske točnosti prepoznavanja.

Označeni pragovi u tablicama daju najbolje rezultate za pojedinu snimku i koriste se u daljnjoj usporedbi s metodom VPS. Na rezultatima snimke V8 može se primijetiti da, u slučajevima s niskim točnostima praćenja, mjere MOTA i MOTP ne daju uvjerljiv optimalni prag mjere anomalnosti, dok se iz vrijednosti mjera HOTA i IDF1 jasno može odrediti da taj prag iznosi 800. Ta je razlika u kvaliteti mjera manje izražena kada su vrijednosti mjera vrlo niske (V15).

Tablica 3.17. predstavlja rezultate praćenja metodama VPS i KNN na snimkama V8 i V15. Metoda VPS na V8 ostvaruje bolje rezultate od metode KNN kroz sve mjere osim točnosti i odziva pridruživanja. Obje metode pokazuju slične rezultate na snimci V15 i na njoj rade lošije u odnosu na snimku V8, što je očekivano s obzirom na visoku razinu šuma u V15. Iako je preciznost pridruživanja relativno visoka na svim primjerima, niski odziv pridruživanja u konačnici uzrokuje smanjenu točnost. Unatoč tome, metoda KNN nadmašuje metodu VPS u vidu točnosti pridruživanja. Točnost prepoznavanja niska je na snimci V15 za obje metode zbog niske preciznosti. To nije slučaj za metodu VPS i snimku V8 na kojoj je točnost prepoznavanja znatno veća od ostalih, zbog čega je u tom slučaju postignuta sveukupno najveća mjera HOTA.

**Tablica 3.17.** Usporedba točnosti praćenja objekata metodama VPS i KNN na osnovu mjere HOTA. Eksperimenti su provedeni na snimkama V8 i V15, a za metodu KNN prikazani su najbolji rezultati iz tablica 3.15. i 3.16.

| <b>Snimka</b> | <b>Metoda</b> | <b>HOTA</b> | <b>DetA</b> | <b>DetRe</b> | <b>DetPr</b> | <b>AssA</b> | <b>AssRe</b> | <b>AssPr</b> | <b>LocA</b> |
|---------------|---------------|-------------|-------------|--------------|--------------|-------------|--------------|--------------|-------------|
| V8            | VPS           | <b>14.0</b> | <b>20.7</b> | <b>34.5</b>  | <b>29.6</b>  | 9.6         | 10.7         | <b>48.0</b>  | <b>72.5</b> |
|               | KNN           | 6.8         | 3.8         | 20.8         | 4.3          | <b>12.7</b> | <b>14.1</b>  | 39.8         | 65.3        |
| V15           | VPS           | 2.1         | <b>0.8</b>  | 40.6         | <b>0.8</b>   | 5.9         | 6.1          | 48.1         | <b>70.9</b> |
|               | KNN           | <b>2.3</b>  | 0.5         | <b>42.6</b>  | 0.5          | <b>11.4</b> | <b>12.2</b>  | <b>51.8</b>  | 68.8        |

## 4. Zaključak

Analiza toplinskih snimki pronalazi primjene u širokom rasponu područja kao što su nadzor, medicina i sigurnost, pa čak i u konzervacijskoj biologiji za potrebe praćenja aktivnosti životinja. Međutim, zbog načina akvizicije toplinskih podataka, u takvim je slikama često izražen šum koji otežava prepoznavanje sitnih objekata. Postojeće metode koje obrađuju toplinske snimke u cilju praćenja preleta ptica i šišmiša ograničene su na praćenje onih životinja koje su relativno blizu kamere i koje stoga na slici imaju veliku površnu.

U ovom je radu predložena nenadzirana metoda za prepoznavanje sitnih objekata koja anomalnost neke točke u snimci računa kao srednju udaljenost do njenih  $k$  najbližih susjeda u vremenski bliskim slikama. Postavljanjem praga anomalnosti za svaku se točku slike može odrediti nalazi li se na njoj praćeni objekt ili ne. Uz to su opisani principi prepoznavanja preleta iz [12] i [11] te je predložen spoj tih dvaju metoda i istražene su njegove mogućnosti na prepoznavanju vrlo malih objekata. U obje su metode prepoznati objekti pridruživani u trajektorije koristeći filtar  $\alpha$ - $\beta$  i pohlepno pridruživanje podataka dužim trajektorijama.

Evaluacija je provedena na podacima prikupljenim tijekom monitoringa aktivnosti životinja u vjetroparku. Točnost praćenja na grubo označenim podacima određena je mjerama visoke razine, a dodatno su za dvije snimke prikupljene i segmentacijske oznake te su na njima metode evaluirane koristeći najčešće mjere točnosti praćenja iz literature. Eksperimentima je utvrđeno da metoda VPS nadmašuje metodu KNN u svim slučajevima osim onom gdje se elise snimljenog vjetroagregata sporo zakreću. Unatoč tome, brzo zakretanje elisa u obje metode rezultira izuzetno velikim brojem lažno pozitivnih trajektorija. Podatkovni je skup dodatno podijeljen na dva podskupa ovisno o izračunatoj razini šuma u pojedinoj snimci kako bi se mogao istražiti utjecaj šuma na

rezultate. Iako su obje metode pri visokim razinama šuma prepoznavale puno lažnih pozitiva, za dio snimki to nije bio slučaj. Ovaj je rezultat ukazao na to da u podacima postoje različite vrste šuma i da one u različitim mjerama utječu na točnost praćenja.

Jedan od najvažniji doprinosa ovog rada je pružena osnova za usmjeravanje budućih istraživanja u ovoj domeni. Šum je inherentan problem u analizi termalnih snimki i uočena je potreba za njegovom detaljnijom kvantifikacijom i analizom njegovog utjecaja na rezultate praćenja. Otvorena je mogućnost za proširenje opisanih metoda prepoznavanja kako bi se smanjio broj lažnih pozitiva. Nadzirana klasifikacija prepoznatih objekata te spoj metode KNN i VPS obećavajući su smjerovi kojima bi se to moglo postići. Klasifikacijom na razini trajektorija mogle bi se raspoznati vrste prepoznatih životinja, ali i filtrirati preleti koji odgovaraju zakretanju elisa vjetroagregata ili šumu u snimci.

## Literatura

- [1] Q. Liu, Z. He, X. Li, i Y. Zheng, “Ptb-tir: A thermal infrared pedestrian tracking benchmark”, *IEEE Transactions on Multimedia*, sv. 22, br. 3, str. 666–675, ožujak 2020. <https://doi.org/10.1109/tmm.2019.2932615>
- [2] B. Milovanovic i I. Banjad Pecur, “Review of active ir thermography for detection and characterization of defects in reinforced concrete”, *Journal of Imaging*, sv. 2, br. 2, str. 11, travanj 2016. <https://doi.org/10.3390/jimaging2020011>
- [3] J. Fulir, L. Bosnar, H. Hagen, i P. Gospodnetic, “Synthetic data for defect segmentation on complex metal surfaces”, u *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE, lipanj 2023. <https://doi.org/10.1109/cvprw59228.2023.00465>
- [4] K. Wang i P. Guo, “An efficient and scalable learning algorithm for near-earth objects detection in astronomy big image data”, u *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. IEEE, listopad 2014. <https://doi.org/10.1109/smc.2014.6973999>
- [5] C. Zheng, J. Pulido, P. Thorman, i B. Hamann, “An improved method for object detection in astronomical images”, *Monthly Notices of the Royal Astronomical Society*, sv. 451, br. 4, str. 4445–4459, srpanj 2015. <https://doi.org/10.1093/mnras/stv1237>
- [6] Z. Wu, N. Fuller, D. Theriault, i M. Betke, “A thermal infrared video benchmark for visual analysis”, u *2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops*. IEEE, lipanj 2014. <https://doi.org/10.1109/cvprw.2014.39>

- [7] J. Zhang, X. Zhou, L. Li, T. Hu, i C. Fansheng, “A combined stripe noise removal and deblurring recovering method for thermal infrared remote sensing images”, *IEEE Transactions on Geoscience and Remote Sensing*, sv. 60, str. 1–14, 2022. <https://doi.org/10.1109/tgrs.2022.3196050>
- [8] C. Conaire, N. O’Connor, E. Cooke, i A. Smeaton, “Comparison of fusion methods for thermo-visual surveillance tracking”, u *2006 9th International Conference on Information Fusion*. IEEE, srpanj 2006. <https://doi.org/10.1109/icif.2006.301618>
- [9] C. L. P. Chen, H. Li, Y. Wei, T. Xia, i Y. Y. Tang, “A local contrast method for small infrared target detection”, *IEEE Transactions on Geoscience and Remote Sensing*, sv. 52, br. 1, str. 574–581, siječanj 2014. <https://doi.org/10.1109/tgrs.2013.2242477>
- [10] E. F. Baerwald, G. H. D’Amours, B. J. Klug, i R. M. Barclay, “Barotrauma is a significant cause of bat fatalities at wind turbines”, *Current Biology*, sv. 18, br. 16, str. R695–R696, kolovoz 2008. <https://doi.org/10.1016/j.cub.2008.06.029>
- [11] S. Matzner, V. I. Cullinan, i C. A. Duberstein, “Two-dimensional thermal video analysis of offshore bird and bat flight”, *Ecological Informatics*, sv. 30, str. 20–28, studeni 2015. <https://doi.org/10.1016/j.ecoinf.2015.09.001>
- [12] M. Betke, D. Hirsh, A. Bagchi, N. Hristov, N. Makris, i T. Kunz, “Tracking large variable numbers of objects in clutter”, u *2007 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, lipanj 2007. <https://doi.org/10.1109/cvpr.2007.382994>
- [13] F. Bolelli, S. Allegretti, L. Baraldi, i C. Grana, “Spaghetti labeling: Directed acyclic graphs for block-based connected components labeling”, *IEEE Transactions on Image Processing*, sv. 29, str. 1999–2012, 2020. <https://doi.org/10.1109/tip.2019.2946979>
- [14] N. Sarafijanovic-Djukic i J. Davis, *Fast Distance-Based Anomaly Detection in Images Using an Inception-Like Autoencoder*. Springer International Publishing, 2019., str. 493–508. [https://doi.org/10.1007/978-3-030-33778-0\\_37](https://doi.org/10.1007/978-3-030-33778-0_37)
- [15] M. Douze, A. Guzhva, C. Deng, J. Johnson, G. Szilvasy, P.-E. Mazare, M. Lomeli,

L. Hosseini, i H. Jegou, “The faiss library”, 2024. <https://doi.org/10.48550/ARXIV.2401.08281>

- [16] Q. H. Ansari, *Metric spaces*. Oxford: Alpha Science Internat., 2010.
- [17] J. Johnson, M. Douze, i H. Jegou, “Billion-scale similarity search with gpus”, *IEEE Transactions on Big Data*, sv. 7, br. 3, str. 535–547, srpanj 2021. <https://doi.org/10.1109/tbdata.2019.2921572>
- [18] S. Blackman i R. Popoli, *Design and analysis of modern tracking systems*, ser. Artech House radar library, S. S. Blackman, Ur. Boston, Mass. [u.a.]: Artech House, 1999., includes bibliographical references and index.
- [19] M. S. Grewal i A. P. Andrews, “Applications of kalman filtering in aerospace 1960 to the present [historical perspectives]”, *IEEE Control Systems*, sv. 30, br. 3, str. 69–78, lipanj 2010. <https://doi.org/10.1109/mcs.2010.936465>
- [20] A. Becker, *Kalman Filter from the Ground Up*. -, 2023.
- [21] K. Bernardin i R. Stiefelhagen, “Evaluating multiple object tracking performance: The clear mot metrics”, *EURASIP Journal on Image and Video Processing*, sv. 2008, str. 1–10, 2008. <https://doi.org/10.1155/2008/246309>
- [22] E. Ristani, F. Solera, R. Zou, R. Cucchiara, i C. Tomasi, *Performance Measures and a Data Set for Multi-target, Multi-camera Tracking*. Springer International Publishing, 2016., str. 17–35. [https://doi.org/10.1007/978-3-319-48881-3\\_2](https://doi.org/10.1007/978-3-319-48881-3_2)
- [23] J. Luiten, A. Osep, P. Dendorfer, P. Torr, A. Geiger, L. Leal-Taixe, i B. Leibe, “Hota: A higher order metric for evaluating multi-object tracking”, *International Journal of Computer Vision*, sv. 129, br. 2, str. 548–578, listopad 2020. <https://doi.org/10.1007/s11263-020-01375-2>
- [24] A. H. Jonathon Luiten, “Trackeval”, <https://github.com/JonathonLuiten/TrackEval>, 2020., [mrežno, stranica posjećena: srpanj 2024.].

# Sažetak

## Praćenje sitnih objekata u toplinskim slikama

Duje Štolfa

Prepoznata je potreba za automatizacijom obrade toplinskih snimki za potrebe monitoringa ornitofaune i faune šišmiša. U pojedinim slučajevima snimljene jedinke mogu biti velike tek nekoliko piksela što ih čini teško primjetnima i što čini ovaj zadatak vrlo zahtjevnim. Rad pristupa praćenju sitnih objekata kao nenadziranom problemu i procjenjuje prikladnost metode za raspoznavanje takvih objekata od pozadine pomoću algoritma pretraživanja k najbližih susjeda i uspoređuje ju s metodama iz literature. Provedenim istraživanjem uspješno su prepoznata ograničenja primjene tih metoda na snimke s izraženim šumom i neželjenim pomacima u sceni te su time postavljeni temelji za razvoj takvog sustava za praćenje.

**Ključne riječi:** analiza toplinskih snimki, monitoring životinja, prepoznavanje anomalija, praćenje objekata, obrada slike



# Abstract

## Tracking small objects in thermal images

Duje Štolfa

The need for an automatic thermal video analysis system has been identified in the field of bird and bat monitoring. What makes this especially challenging is that the recorded animals can appear as small clusters with an area of just a few pixels. This thesis takes this problem on from an unsupervised point of view, assesses the accuracy of a detection method based on the k-nearest neighbours algorithm, and compares it to existing detection methods. The results helped determine edge-cases in the dataset that significantly deteriorated the tracking accuracy, such as noisy videos and videos with unwanted foreground activity.

**Keywords:** thermal video analysis, wildlife monitoring, anomaly detection, tracking, image processing