

Sveučilište u Zagrebu
Fakultet prometnih znanosti

Sandra Stipetić, Mila Ivanković,
Bruno Bilić, Matko Stipičević

**IZRADA YOLO MODELA
ZA DETEKCIJU BESPILOTNIH LETJELICA
NA TERMALNIM SNIMKAMA**

Zagreb, 2025.

Ovaj rad izrađen je u Zavodu za aeronautiku na Fakultetu prometnih znanosti Sveučilišta u Zagrebu pod vodstvom izv. prof. dr. sc. tech. Tomislava Radišića i predan je na Natječaj za dodjelu Rektorove nagrade za akademsku godinu 2024./2025.

SADRŽAJ

1. UVOD	1
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA.....	3
3. METODOLOGIJA.....	6
4. PRIPREMA BESPILOTNIH LETJELICA I SNIMANJE	8
5. TRENIRANJE YOLO MODELA NA VIZUALNIM SNIMKAMA.....	16
5.1. Prvo treniranje modela	18
5.2. Drugo treniranje modela.....	23
6. DETEKCIJA BESPILOTNIH LETJELICA NA VIZUALNIM SNIMKAMA	28
7. KREIRANJE SKUPA PODATAKA S TERMALNIM SNIMKAMA	30
7.1. Pretvaranje koordinata	30
7.2. Dorađivanje skupa podataka u <i>Roboflow</i> -u.....	33
8. YOLO MODEL ZA TERMALNE SNIMKE	35
8.1. Treniranje 1. modela	35
8.2. Treniranje 2. modela	38
8.3. Treniranje 3. modela	40
8.4. Treniranje 4. modela	43
9. ANALIZA	46
9.1. Validacija modela	47
9.2. Primjena modela	54
10. ZAKLJUČAK.....	59
ZAHVALE	61
LITERATURA	62
SAŽETAK	66
SUMMARY	67
POPIS SLIKA	68
POPIS GRAFOVA	69
POPIS TABLICA.....	70
POPIS KODOVA	70
PRILOG 1. <i>PYTHON</i> KOD TRANSFORMACIJE KOORDINATA	71
ŽIVOTOPISI AUTORA.....	73

1. UVOD

U posljednjih nekoliko godina bespilotne letjelice su postale sve prisutnije i koriste se u različite svrhe. Koriste ih amateri za svoje hobije, a sve češće i profesionalne službe. Dolaze u različitim izdanjima, od onih koji se mogu kupiti u dućanu, mase dvjestotinjak grama te stanu u ljudsku ruku pa do onih mase i do 10 tona, specifičnih namjena s mogućnošću nošenja municije. Sa sve većom prisutnošću bespilotnih letjelica pojavila se i potreba za sustavima koji ih mogu otkriti i pratiti u svim vremenskim uvjetima. Budući da u današnje vrijeme ne postoji sustav nalik zrakoplovnom radaru koji bi mogao nadzirati bespilotne letjelice po cijelom nebu, nužno je posjedovati drugačiji način osiguranja kontroliranih letova bespilotnih letjelica. Sustavi za detekciju objekata na snimkama u vidljivom dijelu spektra daju dobre rezultate kod povoljnih vremenskih uvjeta. Međutim, njihova je učinkovitost često ograničena noću, pri magli, dimu ili drugim uvjetima smanjene vidljivosti. Kako bi se zaobišla ta ograničenja, u ovom radu fokus je stavljen na detekciju bespilotnih letjelica na termalnim snimkama. Termalna kamera bilježi toplinsko zračenje objekata, pa bespilotna letjelica ostaje vidljiva čak i kad je golim okom ne možemo uočiti. To omogućuje prepoznavanje bespilotnih letjelica neovisno o svjetlosnim uvjetima i pomaže u njihovom razlikovanju od pozadina i kada su vizualno nevidljive.

Cilj ovog rada bio je razviti model koji će s visokom preciznošću detektirati bespilotne letjelice na termalnim snimkama. Također, dodatni cilj bio je u što većoj mjeri izbjeći ručno označavanje bespilotnih letjelica na snimkama. S time na umu prvotno je razvijen model za detekciju bespilotnih letjelica na vizualnim snimkama kako bi se automatizirala izrada skupa termalnih snimaka na kojem će se novi model trenirati. U ovom radu detaljno je opisan cijeli proces od pripreme bespilotnih letjelica i samog snimanja, preko izrade i dorade skupova podataka, do odabira YOLO modela te su prikazani rezultati svakog treniranja. Rad je podijeljen u devet dijelova:

1. Uvod
2. Pregled dosadašnjih istraživanja
3. Metodologija
4. Priprema bespilotnih letjelica i snimanje
5. Treniranje YOLO modela na vizualnim snimkama

6. Detekcija bespilotnih letjelica na vizualnim snimkama
7. Kreiranje skupa podataka s termalnim snimkama
8. YOLO model za termalne snimke
9. Analiza
10. Zaključak.

U drugom poglavlju dan je pregled prijašnjih istraživanja na području termalnih snimaka i detekcije objekata pomoću YOLO modela. Treće poglavlje opisuje i daje pregled načina provedbe rada. Slijedi poglavlje o pripremi bespilotnih letjelica i snimanju, s uvjetima, lokacijama i koracima potrebnim za dobivanje kvalitetnih vizualnih i termalnih snimki.

Peto poglavlje objašnjava odabir YOLO modela te njegovu strukturu i princip rada. U njemu iskazani rezultati treniranja na vizualnim snimkama. U šestom poglavlju posebno je opisan proces detekcije bespilotnih letjelica i ručnog označavanja snimki na platformi *Roboflow*. U sedmom poglavlju opisana je izrada skupa podataka s termalnim snimkama, koja uključuje osmišljavanje matematičkih formula za pretvorbu koordinata točaka s vizualnih na termalne snimke.

Osmo poglavlje prikazuje četiri faze treniranja YOLO modela na termalnim snimkama. U devetom poglavlju iskazani su konačni rezultati rada i njihova vrijednost i primjena u industriji i sigurnosti zračnog prometa.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

U nastavku je prikazan pregled dosadašnjih istraživanja u području primjene termalnih kamera, YOLO modela i metoda detekcije bespilotnih letjelica te njihove prednosti i ograničenja.

Cilj istraživanja [1] bio je odrediti granicu detektibilnosti tri različite bespilotne letjelice u uvjetima smanjene vidljivosti noću pomoću termalnog senzora niže kvalitete i ljudskog analitičara. Korištene bespilotne letjelice bile su pogonjene malim elektromotorima koji, zbog svoje visoke toplinske iskoristivosti, ne proizvode velike količine toplinske energije u usporedbi s velikim zrakoplovima na mlazni pogon. Sve tri bespilotne letjelice morale su proći jednaku putanju udaljavajući se od kamere konstantnom brzinom, dok je ljudski analitičar pratio njenu poziciju u stvarnom vremenu te zabilježio točnu lokaciju gubitka vizualnog kontakta na ekranu. Zaključeno je da su baterije bolji izvor toplinske energije od elektromotora jer oko njih ne dolazi do opstrujavanja zraka koji bi ih hladio te su zbog toga prepoznatljivije na termalnim snimkama. Dokazano je da je moguće detektirati bespilotne letjelice koje su pogonjene elektromotorom kamerom koja je opremljena termalnim senzorom niže kvalitete. Također maksimalni domet detekcije bio je manji od predviđanja. Vjeruje se da će daljnjim testiranjima biti postignuti bolji rezultati.

U istraživanju [2] provodila se detekcija bespilotnih letjelica termalnim kamerama na uređajima ograničenih resursa. Predstavljena su tri konfliktna problema u dolasku do tog cilja, a to su: velika preciznost u detekciji termalnih otisaka na razini jednog piksela, procesuiranje u stvarnom vremenu te mogućnost rada na uređajima s ograničenim resursima. Kao rješenje su predložili korištenje YOLO11-AU-IR modela. To je model niske složenosti koji se koristi za otkrivanje i segmentaciju malih objekata te za to unutar sebe posjeduje tri arhitektonska poboljšanja: EADown (engl. *Efficient Adaptive Downsampling*), HSAN (engl. *HeteroScale Attention Network*) i ATFL (engl. *Adaptive Threshold Focal Loss*) koji zajedno donose najbolje rezultate gledajući stabilnost i točnost detekcije te su ostvarili zadane ciljeve. Za potrebe provođenja eksperimenta su izradili vlastiti skup podataka termalnih snimki te su validaciju svojeg modela provodili na validacijskom podskupu originalnog skupa.

Švedski znanstvenici u istraživanju [3] napravili su sustav za detekciju bespilotnih letjelica koristeći fuziju tri različita senzora: vizualni, termalni i akustični. Što se tiče termalnog dijela rada, detekcija korištenjem termalne kamere provedena je pomoću računalnog modela YOLO v2. Cilj istraživanja bio je detektirati i pratiti bespilotnu letjelicu s različitih udaljenosti u stvarnom vremenu. Tijekom istraživanja korištena su tri tipa bespilotnih letjelica te termalna kamera tipa *FLIR Breach PTQ-136*. Nakon snimljenog određenog broja videozapisa u trajanju od 10 sekundi, novonastali skup podataka je segmentiran u podskupove za validaciju i treniranje te je provedeno *frame-by-frame* označavanje okvira unutar kojega su se nalazile bespilotne letjelice. Istraživanje je zaključilo da će se bespilotna letjelica teže uočiti ukoliko se udaljenost od termalne kamere do letjelice povećava. Također, ponekad je umjesto bespilotne letjelice na termalnoj kameri uočen i uokviren vrh oblaka ili manji oblak, što je predstavljalo nezadovoljavajući rezultat. Daljnjim istraživanjima te korištenjem novijih verzija programskog sustava YOLO, vjeruje se da će biti manje detekcija krivo označenih objekata poput malih oblaka ili insekata koji su zamijenili bespilotne letjelice.

U istraživanju [4] predstavljen je napredan sustav za nadzor bespilotnih letjelica koji kombinira detekciju i praćenje pomoću konvolucijskih neuronskih mreža. Sustav se temelji na kombinaciji vidljivih i termalnih snimaka. Najveći izazov u izradi takvog sustava bio je nedostatak dovoljno raznolikih termalnih podataka za treniranje modela. Ovaj problem riješen je primjenom različitih tehnika augmentacije podataka čime su generirane dodatne snimke. Za vidljive snimke stvorene su sintetičke snimke pomoću 2D i 3D modela bespilotnih letjelica na raznim pozadinama, dok je za termalne podatke primijenjen modificirani Cycle-GAN pristup kako bi se iz vidljivih snimki stvorili realistični termalni prikazi. Za detekciju bespilotnih letjelica korišten je model *Faster R-CNN*, dok je za praćenje upotrijebljen MDNet modul za praćenje uz dodatnu analizu razlika između kadrova. Ova kombinacija omogućila je bolje razlikovanje bespilotne letjelice od složene pozadine i smanjila broj pogrešnih detekcija. Sustav je testiran na USC bazi podataka koja je obuhvaćala i vidljive i termalne videozapise s ručno označenim bespilotnim letjelicama. Rezultati su pokazali da kombinacija detektora i modula za praćenje daje bolje performanse od korištenja drugih metoda te omogućuje pouzdano praćenje bespilotnih letjelica i danju i noću. Unatoč tome, sustav je osjetljiv na zamućene snimke i u situaciji kada bespilotna letjelica izlazi iz vidnog polja kamere što ostavlja prostor za daljnja poboljšanja.

Za razliku od navedenih istraživanja, cilj ovog rada bio je pomoću termalne kamere, koja je ugrađena na jednu bespilotnu letjelicu, detektirati drugu bespilotnu letjelicu. Ovo istraživanje se razlikuje od ostalih jer se izrada termalnog skupa podataka za treniranje modela za detekciju bespilotnih letjelica zasnivala na pretvorbi iz vizualnog skupa podataka čime je većinski automatiziran taj proces. Skup podataka pažljivo je izrađen koristeći bespilotne letjelice pet različitih dimenzija i oblika koje su snimane na jednostavnim i zahtjevnim pozadinama te iz više i manje prepoznatljivih kutova. Za validaciju je korišten nezavisan skup podataka s bespilotnim letjelicama i pozadinama koje se u potpunosti razlikuju od onih na kojima je vršeno treniranje, a ne na podskupu originalnog skupa. Također, treniranje modela obavljalo se u nekoliko pokušaja dobivajući različite rezultate koji su bili korisni za usporedbu. Svako poboljšanje bio je korak prema konačnoj verziji modela. Nadalje, detekcija bespilotnih letjelica u ovom radu zasniva se na računalnoj detekciji putem YOLO11x modela na pojedinačnim termalnim snimkama, a ne na ljudskoj analizi kontinuiranih videosnimki ili videozapisa uživo na kojima se mogu izvući dodatne informacije o poziciji na temelju kretanja objekta kojeg se detektira. Razvijeni model koji je izrađen u ovome radu pokazuje da ga je moguće koristiti u različitim sustavima nadzora.

3. METODOLOGIJA

Razvoj modela za detekciju bespilotnih letjelica na vizualnim i termalnim snimkama sastojao se od niže navedenih postupaka.


Zadatak je započeo pripremom bespilotnih letjelica, koja je uključivala provjeru stanja različitih vrsta bespilotnih letjelica i primjenu određenih korekcija kako bi ih se moglo koristiti. Sljedeći korak u razvoju modela za detekciju bespilotnih letjelica bio je detaljno istraživanje programa za detekciju bespilotnih letjelica, pri čemu je fokus bio na razumijevanju temeljnih principa rada programa te svojstva koja su bila ključna za detekciju bespilotnih letjelica. Korišten je program YOLO (engl. *You Only Look Once*) tvrtke Ultralytics (SAD) te je odabrana optimalna verzija za detekciju – YOLO11x. Nakon odabira modela, započeto je treniranje modela za detekciju bespilotnih letjelica na vizualnim snimkama. U tu svrhu razvijen je kod za pokretanje cjelokupnog programa za detekciju u programskom jeziku *Python*. Za treniranje modela korišten je skup podataka koji sadrži slike bespilotnih letjelica. Nakon inicijalnog treniranja, dobiveni rezultati poslužili su kao osnova za njegov daljnji napredak. Za unaprjeđenje točnosti detekcije bilo je potrebno proširiti skup podataka te ponovno pokrenuti proces treniranja modela. S tim unaprjeđenjem povećana je preciznost i smanjene su pogreške našeg sustava za detekciju.

Sljedeći korak, bio je neovisan od drugih koraka, a to je snimanje različitih vrsta bespilotnih letjelica i u vidljivom i u termalnom dijelu spektra, u svrhu prikupljanja potrebnih snimaka za daljnji rad. Snimanje se odvijalo u tri dana od kojih su dva bila za vrijeme sunčevog svjetla, a jedno po noći te je obavljeno naknadno. Nakon treniranja, učitane su snimke i stvoren je skup podataka, s ciljem provjere učinkovitosti detekcije na snimkama. Razvijeni sustav je uspješno detektirao bespilotne letjelice na nešto manje od polovice snimki u vidljivom dijelu spektra, dok se drugi dio snimki trebao učitati na platformu *Roboflow* koji omogućuje ručno označavanje objekata na snimkama pravokutnim okvirima (dalje u tekstu korišten engleski naziv: *bounding box*). Potom je osmišljena matematička formula za transformaciju koordinata *bounding box*-ova na vizualnim snimkama u koordinate na termalnim snimkama. Od tih termalnih snimki i njihovih *bounding box*-ova napravljen je novi termalni skup podataka pomoću platforme *Roboflow*.

Skup podataka je dalje korišten za treniranje novog modela koji će detektirati bespilotne letjelice na termalnim snimkama. Kako bi se dodatno obogatio skup

podataka i povećala raznolikost snimki, izvedeno je noćno snimanje bespilotnih letjelica. Time je omogućeno treniranje modela na snimkama nastalim u uvjetima smanjenje vidljivosti. Završno treniranje modela provedeno je na svim dostupnim snimkama, što je rezultiralo preciznijom detekcijom bespilotnih letjelica na termalnim snimkama i povećalo točnost u različitim uvjetima snimanja.

Hodogram opisane metodologije prikazan je na slici 1.



Slika 1. Hodogram izrade projekta

4. PRIPREMA BESPILOTNIH LETJELICA I SNIMANJE

Prije početka snimanja bilo je potrebno obaviti pripremu bespilotnih letjelica. Korišteno ih je pet, a to su: *Xiaomi FIMI X8 SE*, *DJI Inspire 1 v2* i tri ručno izrađene bespilotne letjelice, pa stoga nemaju službena imena modela nego se u ostatku rada zovu „kvadkopter“, „heksakopter“ i „dodekakopter“. Snimanje se vršilo pomoću bespilotne letjelice *DJI Mavic 2 Enterprise Dual* koja je opremljena s dvije kamere, jednom za snimanje u vidljivom, a drugom za snimanje u termalnom dijelu spektra. Ta bespilotna letjelica prikazana je na slici 2.



Slika 2. Bespilotna letjelica *DJI Mavic 2 Enterprise Dual*

Bespilotna letjelica tipa „kvadkopter“ bila je spremna za let, te na njoj nije bilo potrebno puno toga napraviti. Međutim, na bespilotnoj letjelici tipa „dodekakopter“ bile su potrebne određene pripreme za let. Prije nego što se započelo s praktičnim radom, bilo je potrebno detaljnije proučiti principe funkcioniranja bespilotne letjelice i njezine ključne dijelove. To je pružilo bolje razumijevanje strukture i mehanike letjelica, što je bilo korisno za zadatke koji su slijedili. Zbog vremenskih ograničenja, fokus je bio na pripremi „dodekakopter“ bespilotne letjelice, dok se bespilotna letjelica tipa „heksakopter“ u tom trenutku nije stigla osposobiti za vrijeme nastave. Nedostajali su joj dijelovi potrebni za samostalan let.

Priprema bespilotne letjelice tipa „dodekakopter“ uključivala je nekoliko specifičnih koraka:

1. uklanjanje gimbala: gimbal, koji služi kao stabilizirani nosač za kameru, nije bio potreban za ovaj specifični zadatak prikupljanja podataka za detekciju same bespilotne letjelice. Štoviše, samo bi nepotrebno otežavao bespilotnu letjelicu i trošio energiju baterije. Gimbal je uklonjen primjenom tzv. principa „quick release“ – bilo ga je potrebno snažno i brzo povući kako bi se odvojio od tijela bespilotne letjelice.
2. popravak i ponovno postavljanje GPS modula: primijećeno je da se GPS modul odlijepio s gornjeg dijela bespilotne letjelice tipa „dodekakopter“. Za ponovno sigurno pričvršćivanje, bilo je potrebno prvo ukloniti staru obostrano ljepljivu pločicu. Ostaci starog ljepila pažljivo su ostrugani pomoću skalpela, a površina je zatim očišćena alkoholom kako bi se osiguralo dobro prijanjanje nove ljepljive pločice. Nakon čišćenja, postavljena je nova obostrano ljepljiva pločica na koju je zatim fiksiran GPS modul.
3. izolacija i osiguravanje komponente: dio na bespilotnoj letjelici tipa „dodekakopter“ zahtijevao je dodatnu izolaciju i osiguranje. Na vrh tog dijela postavljen je mali plastični element. Kako taj plastični dio nije čvrsto stajao sam od sebe, bilo ga je potrebno omotati ljepljivom trakom kako bi se dovoljno pričvrstio i osigurao njegov položaj tijekom leta.

Nakon priprema, bespilotnu letjelicu je trebalo povezati s računalom i programom *Mission Planner*. *Mission Planner* je zemaljska kontrolna stanica otvorenog koda za program *Pixhawk* i druge kompatibilne autopilote, te omogućuje konfiguraciju, planiranje misija i praćenje leta. Međutim, prilikom pokušaja povezivanja, uočen je problem: GPS nije ispravno radio te je softver na računalu pokazivao netočnu lokaciju bespilotne letjelice. To je ukazalo na potrebu za kalibracijom GPS-a. Kalibracija GPS-a, koja je ključna za precizno pozicioniranje i siguran let, nije se mogla napraviti u zatvorenom prostoru, pa je kalibracija GPS sustava obavljena prije samog leta.

Kada je bespilotna letjelica bila potpuno pripremljena, pristupljeno je ključnoj fazi – snimanju fotografija. Odabir dana za snimanje bio je uvjetovan povoljnim vremenskim prilikama; vedro nebo i mirno vrijeme bez značajnog vjetrova ili padalina bili su obavezni uvjeti za obavljanje leta. Dobri vremenski uvjeti ključni su ne samo radi sigurnosti

samog leta i izbjegavanja potencijalnih oštećenja opreme, već i radi osiguravanja visoke kvalitete snimaka s dobrom vidljivošću bespilotne letjelice. Snimanje je obavljeno na pažljivo odabranom otvorenom prostoru, daleko od prepreka i ljudi, uz strogo poštivanje svih sigurnosnih procedura i važećih propisa o letenju bespilotnim letjelicama.

Primarni cilj bio je zabilježiti bespilotnu letjelicu u što raznovrsnijim uvjetima leta kako bi se stvorio bogat i varijabilan skup snimaka za budući trening. U cilju stvaranja raznolikog skupa podataka, snimke su morale biti napravljene:

- na različitim visinama: od niskih visina, gdje pozadina može biti kompleksnija (tlo, vegetacija, objekti), do većih visina gdje je bespilotna letjelica češće projicirana naspram neba. Ovo pomaže modelu da nauči razlikovati bespilotnu letjelicu od različitih tekstura i oblika u pozadini.
- na različitim udaljenostima od kamere: snimanje izbliza omogućava bilježenje više detalja o strukturi bespilotne letjelice, dok snimanje s veće udaljenosti rezultira manjim prikazom bespilotne letjelice na snimci, što testira sposobnost modela da detektira manje objekte.
- pod različitim kutovima snimanja: bespilotna letjelica je snimana iz različitih perspektiva – odozdo, sa strane, odozgo te pod kosim kutovima. Svaki kut otkriva drugačiji profil i skup vizualnih značajki bespilotne letjelice.
- s različitim pozadinama: osim čistog neba, koje je često najlakši scenarij za detekciju, snimanje bespilotnih letjelica izvodilo se i ispred kompleksnijih pozadina kao što su krošnje drveća ili pročelja zgrada. Takve pozadine mogu prikriti bespilotnu letjelicu i predstavljaju veći izazov za algoritme detekcije.

Tijekom prvog snimanja, koristile su se sljedeće bespilotne letjelice: *Xiaomi FIMI X8 SE*, *DJI Inspire 1 v2*, „heksakopter“ i „kvadkopter“.

Tijekom drugog snimanja korištena je bespilotna letjelica „dodekakopter“, koja nije uspjela poletjeti te se snimanje obavilo isključivo s bespilotnom letjelicom pozicioniranom na zemlji, tj. na različitim pozadinama (travnato tlo i asfalt). Snimanje se obavilo na košarkaškom igralištu na Kampusu Borongaj.

Tijekom posljednjeg snimanja koje je obuhvatilo popodnevne sate i noć opet je korištena bespilotna letjelica „dodekakopter“. Ta letjelica koja na prethodnim snimanjima nije uspjela poletjeti, ovoga je puta bila bolje pripremljena kako bi se osigurala njezina potpuna funkcionalnost. U sklopu priprema ugrađene su navigacijske lampice, čime se značajno olakšala vidljivost bespilotne letjelice u mraku i prepoznatljivost smjera kretanja tijekom leta. Povoljni vremenski uvjeti omogućili su snimanje visoke kvalitete, bogato kontrastima i velikom količinom vidljivih detalja.

Cilj ovog snimanja bio je prikupiti što raznovrsnije snimke bespilotne letjelice u letu s naglaskom na različite pozadine i scenarije snimanja tijekom noći. Prikupljene snimke doprinose cjelovitosti postojećeg skupa podataka te unaprjeđuju sposobnost sustava za detekciju bespilotnih letjelica u širokom spektru uvjeta.

Uvjeti tijekom svih snimanja prikazani su u tablici 1.

Tablica 1. Uvjeti tijekom snimanja

	1. snimanje	2. snimanje	3. snimanje	
Datum	3. 4. 2025.	4. 4. 2025.	20. 6. 2025.	
Vrijeme	9:00 Sunčano i vedro	9:00 Oblačno	17:00 Sunčano i vedro	21:30 Vedro
Temperatura [°C]	11	10	28	22
Vidljivost [km]	≥ 10	5 – 10	≥ 10	≥ 10
Brzina [kn] i smjer vjetrova	≤ 5 (slab), istočni	≥ 10 (umjeren), jugozapadni	≤ 6 (slab), jugozapadni	≤ 3 (slab), zapadni
Oblaci	Bez naoblake	Djelomična naoblaka	Bez naoblake	Bez naoblake
Lokacija	Kampus Borongaj – pored objekta 210	Kampus Borongaj – košarkaško igralište	Otvorena površina na Kampusu Borongaj	

Izvor: [5]


Na sljedećim slikama prikazane su bespilotne letjelice koje su se koristile za snimanje. Slike prikazuju spojene vizualnu i termalnu snimku bespilotne letjelice. S lijeve strane nalazi se termalna snimka, a s desne vizualna snimka.

Slika 3 prikazuje bespilotnu letjelicu *Xiaomi FIMI X8 SE*. To je mala bespilotna letjelica bijele boje snimljena u poziciji „pod nož“ i s pozadinom drveća.



Slika 3. Bespilotna letjelica *Xiaomi FIMI X8 SE*

Slika 4 prikazuje bespilotnu letjelicu tipa „dodekakopter“. Crne je boje većih dimenzija s 12 motora i 12 propelera. Snimljena je na travnatoj površini i odozgo.



Slika 4. Bespilotna letjelica tipa „dodekakopter“

Slika 5 prikazuje беспilotnu letjelicu tipa „heksakopter“. To je crna беспilotna letjelica s 6 motora i 6 propelera, također većih dimenzija. Snimljena je na nebeskoj pozadini i odozdo.



Slika 5. Беспilotna letjelica tipa „heksakopter“

Slika 6 prikazuje беспilotnu letjelicu tipa „kvadkopter“. Manja беспilotna letjelica crno-narančaste boje s 4 mala motora i 4 manja propelera. Snimljena je na travnatoj površini i odozgo.



Slika 6. Беспilotna letjelica tipa „kvadkopter“

Slika 7 prikazuje bespilotnu letjelicu *DJI Inspire 1 v2*. Snimljena je tako da je u pozadini vidljiva građevina i iz pozicije „pod nož“. Manjih je dimenzija s 4 motora i 4 propelera.



Slika 7. Bespilotna letjelica *DJI Inspire 1 v2*

Slika 8 prikazuje bespilotnu letjelicu tipa „dodekakopter“. Snimljena je u uvjetima smanjenosti vidljivosti odnosno tijekom noći. U pozadini se nalazi asfaltna površina te je snimljena odozgo. Također su vidljive i navigacijske lampice.



Slika 8. Bespilotna letjelica tipa „dodekakopter“ tijekom noćnog snimanja

Sva ova pažljivo planirana raznolikost u prikupljenim podacima bila je bitna. Njen cilj nije bio samo povećati broj snimaka, već stvoriti bogat i reprezentativan skup podataka koji će model „naučiti“ što bespilotna letjelica uistinu jest, neovisno o specifičnom kontekstu u kojem se pojavljuje, tj. učiniti model robusnim. Time se direktno utječe na sposobnost modela da prepozna bespilotnu letjelicu u različitim uvjetima i precizno detektira bespilotne letjelice u širokom spektru novih, prethodno neviđenih situacija i okruženja, što je temeljni preduvjet za njegovu praktičnu upotrebljivost.

5. TRENIRANJE YOLO MODELA NA VIZUALNIM SNIMKAMA

Detekcija objekata definira se kao postupak identificiranja određenih objekata koristeći tehnike obrade snimki. U ovom radu detektirale su se bespilotne letjelice, a za taj zadatak odabran je i implementiran model YOLO11x, najnoviji model tvrtke Ultralytics. YOLO kao algoritam razvijen je 2015. te se od tadašnje verzije YOLO1 do današnje snažno rasprostranio u detekciji objekata. Na slici 9 prikazana je vremenska lenta razvoja YOLO modela, [6].



Slika 9. Razvoj YOLO modela tijekom godina, [6]

Pri odabiru modela za detekciju bespilotnih letjelica važno je razumjeti razlike između jednostupanjskih (engl. *single-stage*) i dvostupanjskih (engl. *two-stage*) detektora jer one direktno utječu na kompromis između brzine i preciznosti. Dvostupanjski detektori poput *Faster R-CNN* temelje se na principu gdje se najprije generiraju prijedlozi regija s potencijalnom lokacijom objekta, a zatim se te regije detaljno klasificiraju kako bi se precizno identificirala prisutnost i klasa objekta. Ova je metoda visoke točnosti i preciznosti lokalizacije, ali dolazi uz veću računsku složenost i sporije vrijeme obrade što ga čini manje pogodnim za primjene u stvarnom vremenu. Jednostupanjski detektori, poput YOLO modela detektiraju i klasificiraju objekte u jednom prolazu kroz mrežu. Na taj način mreža analizira sve moguće lokacije bespilotnih letjelica unutar snimke čime se značajno povećava brzina obrade. Ova metoda pogodna je za primjenu u stvarnom vremenu poput nadzora bespilotnih letjelica u prostoru. Ranije verzije jednostupanjskih detektora bile su manje precizne u usporedbi s dvostupanjskim detektorima, ali novije verzije YOLO modela postigle su balans između brzine i točnosti. Zbog toga se upravo oni najčešće koriste jer je važno brzo i pouzdano prepoznati bespilotne letjelice. Novi pristupi temeljeni na transformerima, poput *Swin Transformer* ili DETR modela, također pokazuju obećavajuće rezultate u detekciji objekata. Njihova prednost leži u sposobnosti globalnog razumijevanja slike, što može

dodatno poboljšati točnost detekcije. Međutim, treniranje ovih modela zahtijeva velike količine podataka kako bi se postigla stabilna konvergencija, što ih u praksi čini manje dostupnima za specifične primjene gdje je skup podataka ograničen, [6, 7].

YOLO11x odabran je zbog svojih naprednih mogućnosti u detekciji objekata u realnom vremenu, omogućuje preciznu detekciju objekata i treniranje modela na vlastitim snimkama. Sveobuhvatan je, raznolik, jednostavan za korištenje te odlično potkrijepljen ažuriranom korisničkom dokumentacijom. To je najveći i najbrži unaprijed istrenirani YOLO11 model koji se može koristiti za najsloženije operacije za razliku od svojih manjih verzija (YOLO11n, YOLO11s, YOLO11m i YOLO11l). Osim za detekciju objekata, ovaj model koristi se i za segmentaciju snimaka, klasifikaciju snimaka te procjenu ljudskih poza, [6, 8].

Svako treniranje YOLO modela ima tri faze: inicijalizacija, treniranje i validacija. Tijekom inicijalizacije postavlja se arhitektura YOLO modela u koju pripadaju slojevi, parametri i strukture te se postavlja početna težina modela o kojoj značajno ovise brzina učenja i konačan rezultat. Slojevi predstavljaju pojedinačne komponente YOLO modela koji obavljaju pojedine funkcije, a unutar modela može ih biti više stotina. Ti slojevi mogu biti ulazni, konvolucijski, aktivacijski, *dense*, *pooling*, *dropout* i dr. Unutar tih slojeva nalaze se parametri koji su ustvari težine koje taj model uči i unaprjeđuje, a struktura modela odnosi se na raspored slojeva i njihovu međusobnu povezanost. Težine se postavljaju nasumično ukoliko se radi o prvom treniranju ili se mogu već naučene prenijeti iz prethodnog treniranja. To onda modelu omogućava da brže nauči određene zadatke. U fazi treniranja događa se prolazak kroz skup podataka gdje model predviđa objekte te računa vrijednosti funkcija gubitaka tj. računa svoje greške u odnosu na stvarne pozicije objekata. Postoje tri takve funkcije koje model prati s obzirom na lokaciju, klasu i prisutnost objekta. Pomoću povratnih informacija model se kontinuirano tijekom treniranja poboljšava te prati svoje metrike kao što su preciznost i odziv. Validacija kao posljednji korak u treniranju modela označava provjeru onoga što je model naučio na skupu snimaka koje su bile posebno izdvojene za tu namjenu te nisu služile prilikom treniranja. Koristi se za otkrivanje pretreniranosti (engl. *overfitting*), [9].

Prvi korak u samom razvoju sustava bio je kreiranje izvršnog koda u programskom jeziku *Python*. Unutar tog koda jasno su definirani parametri za korištenje odabranog YOLO11x.pt modela s primarnim ciljem detekcije bespilotnih letjelica na snimkama.

Kako bi model uspješno trenirao i prepoznao bespilotne letjelice bilo je neophodno osigurati adekvatan skup podataka.

5.1. Prvo treniranje modela


Za osiguravanje adekvatnog skupa podataka korišten je „UAVs“ skup podataka koji je pronađen i preuzet putem platforme *Roboflow*, [10]. Ovaj skup podataka pokazao se pogodnim zbog svog sadržaja, obuhvaćajući 9262 snimke iz vidljivog dijela spektra na kojima su jasno označene bespilotne letjelice što je osiguralo dovoljnu količinu podataka za treniranje modela. Unutar Python koda također su specificirani, kako je prikazano u kodu 1, ključni parametri za proces treniranja modela. Zahtijevano je da se treniranje provede kroz 100 epoha što označava broj potpunih prolaza kroz cijeli skup podataka. Nadalje, definirano je da format ulaznih snimki bude 640 x 640 piksela što je standardna rezolucija za YOLO modele koja omogućava dobar balans između preciznosti i brzine obrade, a snimke iz preuzetog skupa podataka već su bile u toj rezoluciji. Radi značajnog ubrzanja procesa treniranja i optimizacije, u kodu je također zahtijevano korištenje 90 % dostupne grafičke procesorske jedinice (GPU). Konkretno, korištena je grafička kartica *NVIDIA GeForce RTX 4060 Ti* s 8 GB memorije. Ovaj zahtjev omogućio je bržu obradu velikog broja snimaka, čime je značajno skraćeno vrijeme potrebno za treniranje modela.

```
from ultralytics import YOLO
model = YOLO("yolo11x.pt")
results = model.train(data="D:/ZIN projekt 2025/UAVs
dataset/data.yaml", epochs=250, imgsz=640, batch=0.9, device=0,
model="yolo11x.pt")
```


Kod 1. Pokretanje prvog treniranja na vizualnim snimkama

Ovakvim postavkama i optimizacijama započeto je inicijalno treniranje modela. Cilj je bio osposobiti model da s maksimalnom mogućom preciznošću i točnošću detektira bespilotne letjelice na priloženim snimkama unutar danog skupa podataka.


Nakon provedenog procesa treniranja modela YOLO11x bilo je ključno analizirati i interpretirati dobivene rezultate kako bi se procijenila učinkovitost sustava u detekciji bespilotnih letjelica. Rezultati treniranja praćeni su na temelju različitih podataka koji omogućuju uvid u sposobnost modela da precizno identificira i locira bespilotne letjelice. Rezultati treniranja modela YOLO11x prikazani su na grafovima 1 – 3 i pružaju sveobuhvatnu sliku o njegovom treniranju tijekom 100 epoha.



Graf 1. Rezultati funkcija gubitka (*train*) prvog treniranja na vizualnim snimkama



Graf 2. Rezultati funkcija gubitka (val) prvog treniranja na vizualnim snimkama



Graf 3. Rezultati funkcija metrika prvog treniranja na vizualnim snimkama

Prvenstveno je bila praćena promjena funkcija gubitaka. Funkcija gubitka predstavlja srž procesa treniranja mjereći „grešku“ modela. Njihovo smanjenje tijekom treniranja indikacija je uspješnog treniranja i adaptacije modela na dostavljene podatke.

Train/box_loss (greška pozicije): ovi podatci predstavljaju koliko predviđene lokacije i dimenzije *bounding box*-ova modela odstupaju od stvarnih lokacija bespilotnih letjelica, [11]. Na početku treniranja, u prvoj epohi, zabilježena je vrijednost od 1,394. Kako je model prolazio kroz daljnje epohe i usvajao značajke iz skupa podataka, vrijednost *train/box_loss* sustavno se smanjivala. Ovaj trend je jasno vidljiv kao padajuća krivulja na grafu, ukazuje na to da je model progresivno poboljšavao svoju sposobnost preciznog lociranja bespilotnih letjelica unutar snimaka. Na samom kraju treniranja, zabilježena je vrijednost od 0,871. Ova niska konačna vrijednost potvrđuje napredak u preciznosti lociranja.

Train/cls_loss (greška klasifikacije): ova funkcija mjeri greške točnog određivanja klasa pronađenih objekata unutar *bounding box*-ova, odnosno ova funkcija je mjera nesigurnosti u to da je detektirani objekt zaista bespilotna letjelica, a ne nešto drugo, [11]. Početna vrijednost u prvoj epohi iznosila je 1,592, što implicira određenu nesigurnost u klasifikaciji na samom početku. Međutim, graf *train/cls_loss* jasno demonstrira konstantan pad, dostižući niske vrijednosti u kasnijim epohama. To svjedoči o značajnom poboljšanju modela u razlikovanju bespilotnih letjelica od drugih elemenata na snimkama. Na kraju analiziranog treniranja, zabilježena je vrijednost od 0,413 što ukazuje na višu razinu pouzdanosti modela u ispravnoj klasifikaciji.

Train/df_l_loss (greška distribucije): ima ulogu u podešavanju preciznosti lokacije i dimenzija *bounding box*-ova. Koristi predviđanje koordinata *bounding box*-ova pomoću distribucije mogućih lokacija te predstavlja razliku između predviđene distribucije i stvarne vrijednosti koordinata *bounding box*-a, [11]. Započevši s vrijednosti od 1,422 u prvoj epohi, njezin konstantan pad na grafu tijekom treniranja ukazuje na to da je model uspješno optimizirao svoju sposobnost da uhvati prostorne detalje i tako dodatno usavrši preciznost lociranja bespilotnih letjelica. Krajnja zabilježena vrijednost ovog gubitka iznosila je 1,092, što demonstrira stabilan napredak u finom podešavanju lokalizacije.

Važno je napomenuti da su prikazani grafovi kako za trening, tako i za validacijski skup podataka. Objašnjenja grafova za validaciju su jednaka onima za trening, s ključnom

razlikom da se validacijske metrike računaju na zasebnom skupu snimaka koje nisu korištene tijekom treniranja modela.

Pored praćenja gubitaka, objektivna procjena performansi modela zahtijeva analizu specifičnih metrika. Njihov porast direktno signalizira poboljšanje sposobnosti modela da uspješno detektira bespilotne letjelice.

Metrics/precision (preciznost): ovaj graf prikazuje udio točno detektiranih bespilotnih letjelica (pravih) u odnosu na sve detekcije koje je model označio kao bespilotne letjelice (prave i lažne). Drugim riječima, ako model kaže da je nešto bespilotna letjelica, kolika je vjerojatnost da to zaista jest. Preciznost je važan podatak za pratiti u slučaju minimiziranja lažnih detekcija, [11]. Računa se po formuli [6]:

$$Preciznost = \frac{TP}{TP + FP}$$

gdje su:

TP – broj ispravno detektiranih objekata (engl. *true positive*)

FP – broj neispravno detektiranih objekata (engl. *false positive*).

Početna vrijednost u prvoj epohi iznosila je 0,823, što je već obećavajuća početna točka. Tijekom treniranja, krivulja preciznosti na grafu prikazuje stabilan i poželjan porast, približavajući se idealnoj vrijednosti 1,0 u kasnijim epohama. Na 100. epohi, preciznost je dosegla 0,932, što znači da je model pouzdaniji u detekciji bespilotnih letjelica, s nižom stopom lažnih pozitivnih detekcija.

Metrics/recall (odziv): odziv otkriva sposobnost modela da pronađe sve stvarne bespilotne letjelice prisutne na snimkama, odnosno odziv je udio pronađenih bespilotnih letjelica od svih stvarnih bespilotnih letjelica na snimci. Odziv je ključan parametar ukoliko je važno detektirati svako pojavljivanje određenog objekta, [11]. Računa se po formuli [6]:

$$Odziv = \frac{TP}{TP + FN}$$

gdje su:

TP – broj ispravno detektiranih objekata (engl. *true positive*)

FN – broj nedetektiranih objekata (engl. *false negative*).

Počevši s vrijednosti od 0,821 u prvoj epohi, graf odziva također prikazuje konstantan i pozitivan trend rasta. Očekuje se da će se ova krivulja također približiti vrijednosti 1,0 (u kasnijim epohama), što bi značilo da model uspijeva detektirati veliku većinu bespilotnih letjelica unutar našeg skupa podataka. Na 100. epohi model doseže vrijednost od 0,927.

Metrics/mAP50 (*Mean Average Precision* 0,5): ova metrika je standardni pokazatelj ukupne performanse modela detekcije objekata. Ona je mjera prosječne preciznosti detekcije uz uvjet da je preklapanje predviđenog *bounding box*-a sa stvarnim *bounding box*-om barem 50 %, [11]. Na početku treniranja, u prvoj epohi, model je zabilježio vrijednost *mAP50* od 0,853. Iako su u drugoj epohi (0,674) i trećoj epohi (0,605) primijećeni privremeni padovi, tipični za početne faze treniranja, graf *mAP50* jasno demonstrira oporavak i vidljiv je uzlazni trend tijekom preostalog procesa treniranja. Postizanje visokih vrijednosti, često iznad 0,95 u kasnijim epohama nedvosmisleno potvrđuje sposobnost našeg modela da postiže bolju preciznost i odziv pod umjerenim kriterijima preklapanja.

Metrics/mAP50-95 (*Mean Average Precision* 0,5 – 0,95): ova metrika nudi strožu i kvalitetniju procjenu performansi modela. Ona predstavlja prosječnu preciznost modela pri različitim pragovima preklapanja od 50 % pa do 95 % s korakom od 5 % testirajući sposobnost modela da postigne visoku preciznost pozicije i pri vrlo strogim kriterijima. Zbog strožih kriterija, vrijednosti *mAP50-95* su niže, [11]. Model je u prvoj epohi startao s 0,497, bilježeći pad na 0,362 u drugoj i 0,305 u trećoj epohi. Unatoč ovim početnim varijacijama, kontinuiran porast krivulje *mAP50-95* na grafu nakon ovih početnih padova je važan pokazatelj. To znači da je model razvio sposobnost preciznije detekcije. Krajnja zabilježena vrijednost na 100. epohi treniranja iznosi 0,680.

5.2. Drugo treniranje modela


Prvo treniranje modela ukazalo je na potrebu za daljnjim unaprjeđenjem modela kako bi se postigao viši stupanj detekcije i zadovoljavajući broj ispravnih prepoznavanja bespilotnih letjelica. Rezultati prvog treniranja jasno su signalizirali potrebu za povećanjem skupa podataka budući da je veličina i raznolikost podataka ključna za

precizniju detekciju bespilotnih letjelica. Stoga je donesena odluka o značajnom proširenju skupa podataka. Inicijalni skup podataka proširen je dodatno drugim skupom, također s platforme *Roboflow* naziva „Drone_07“, koji sadrži 9973 snimke, [12]. Kombinacijom ova dva skupa podataka stvoren je znatno veći, objedinjeni skup podataka s ukupno 19.235 snimki, što je značajno poboljšalo količinu raspoloživih podataka za treniranje. Od ovog ukupnog skupa podataka, 15.483 snimke bile su namijenjene za provedbu drugog treniranja modela. Drugo treniranje bilo je neophodno zbog prvotnog nedovoljnog stupnja detekcije, odnosno nezadovoljavajućeg broja ispravnih prepoznavanja bespilotnih letjelica u različitim scenarijima snimanja. Tijekom drugog intenzivnijeg procesa treniranja i dalje je zadržan YOLO11x.pt model, koji se prethodno dokazao kao učinkovito sredstvo u detekciji bespilotnih letjelica. Kako bi se osigurala optimalna brzina procesa treniranja i dalje je specificirano korištenje 90 % dostupne grafičke procesorske jedinice (GPU). S ovim proširenim skupom podataka i precizno specificiranim parametrima pri čemu je broj epoha povećan sa 100 na 250, započeto je ponovno treniranje modela. Proces drugog treniranja u jednom trenutku bio je zaustavljen, a zatim ponovno pokrenut. Pritom nije došlo do nikakvih gubitaka podataka niti negativnog utjecaja na napredak treniranja. Treniranje je normalno nastavljeno s točke prekida. *Python* kod naredbe za nastavak prekinutog treniranja prikazan je u kodu 2.


```
from ultralytics import YOLO
# Load a model
model = YOLO("D/ZIN projekt
2025/runs/detect/train14/weights/last.pt")
# Resume training
results = model.train(resume=True)
```

Kod 2. Nastavak prekinutog treniranja


Po završetku drugog treniranja uslijedilo je analiziranje dobivenih rezultata. Analiziranjem podataka dobiven je uvid u sposobnost modela da precizno identificira bespilotne letjelice. Rezultati ovog drugog treniranja prikazani su na grafovima 4 – 6 te demonstriraju napredak performansi modela te sposobnost u prepoznavanju bespilotnih letjelica.



Graf 4. Rezultati funkcija gubitka (*train*) drugog treniranja na vizualnim snimkama



Graf 5. Rezultati funkcija gubitka (*val*) drugog treniranja na vizualnim snimkama



Graf 6. Rezultati funkcija metrika drugog treniranja na vizualnim snimkama

Train/box_loss: na početku treniranja u prvoj epohi zabilježena je početna vrijednost od 1,438. Iako je u drugoj epohi došlo do porasta na 1,519, a u trećoj epohi na 1,644, najviša vrijednost od 1,679 dosegnuta je u četvrtoj epohi. Vrijednosti nakon četvrte epohe kontinuirano opadaju. Konačna vrijednost na 250 epohi iznosila je 0,723 što ukazuje da je model progresivno poboljšavao svoju sposobnost preciznog lociranja bespilotnih letjelica unutar snimaka. U završnim epohama treniranja uočava se nagli skok krivulje na vrlo niskim vrijednostima što ukazuje na pojavu preciznog podešavanja (engl. *fine-tuning*). Ova pojava pokazuje da model nakon što je usvojio generalne značajke, u kasnijim fazama treniranja vrši manje prilagodbe svojih performansi. Na taj način dodatno usavršava svoju preciznost i točnost detekcije bespilotnih letjelica. Pojava preciznog podešavanja bila je uočljiva nakon prvog treniranja modela, a bit će uočljiva i na grafovima *train/cls_loss* i *train/dfl_loss*.

Train/cls_loss: početna vrijednost u prvoj epohi iznosila je 1,236. Slično kao i kod *box_loss*, u drugoj epohi zabilježen je manji pad na 1,204, dok je u trećoj epohi došlo do porasta na 1,457. Najviša vrijednost od 1,544 dosegnuta je u četvrtoj epohi nakon čega vrijednosti kontinuirano opadaju. Graf *train/cls_loss* demonstrira kontinuiran pad vrijednosti tijekom procesa treniranja. To opisuje poboljšanje modela u razlučivanju

bespilotnih letjelica od pozadine ili drugih elemenata na snimkama. Na 250. epohi, zabilježena je niska konačna vrijednost od 0,320 što ukazuje na poboljšanu razinu pouzdanosti modela u ispravnoj klasifikaciji.

Train/df_l_loss: započevši s vrijednosti od 1,572 u prvoj epohi te bilježeći porast na 1,632 u drugoj i 1,746 u trećoj epohi, najviša vrijednost od 1,790 dosegnuta je u četvrtoj epohi, nakon čega vrijednosti kontinuirano opadaju. Graf *train/df_l_loss* potom pokazuje konstantan i jasan pad tijekom treniranja. Ovaj trend ukazuje na to da je model usavršio preciznost lociranja bespilotnih letjelica. Konačna zabilježena vrijednost na 250. epohi iznosila je 1,049 što demonstrira stabilan i precizan napredak u finom podešavanju lociranja.

Metrics/precision: početna vrijednost u prvoj epohi iznosila je 0,899. U drugoj epohi zabilježen je pad na 0,853 te u trećoj epohi na 0,787. Nakon ovih početnih fluktuacija graf preciznosti pokazuje brz oporavak te porast približavajući se idealnoj vrijednosti 1,0. Na 250. epohi preciznost je dosegla izvanrednih 0,961 što znači da je model pouzdan u detekciji bespilotnih letjelica s vrlo niskom stopom lažnih pozitivnih detekcija.

Metrics/recall: početna vrijednost u prvoj epohi bila je 0,839. Slično preciznosti, u drugoj epohi bilježimo pad na 0,774, a zatim daljnji pad na 0,726 u trećoj epohi. Međutim, graf odziva demonstrirao je kontinuiran i snažan trend rasta nakon ovih početnih fluktuacija. Na 250. epohi odziv je iznosio 0,959 što potvrđuje da je model učinkovit u prepoznavanju što većeg broja stvarnih bespilotnih letjelica.

Metrics/mAP50: s početnom vrijednosti od 0,908 u prvoj epohi te manjim padom na 0,848 u drugoj i 0,797 u trećoj epohi graf *mAP50* pokazuje snažan uzlazni trend tijekom procesa treniranja. Postizanje i stabilizacija na visokoj vrijednosti od 0,978 na 250. epohi jasno potvrđuje sposobnost modela da postiže visoku preciznost pod blažim kriterijima preklapanja.

Metrics/mAP50-95: početne vrijednosti su niže zbog strožih kriterija. U prvoj epohi model je startao s 0,541 bilježeći pad na 0,457 u drugoj i 0,440 u trećoj epohi. Kontinuiran porast krivulje *mAP50-95* na grafu tijekom treniranja važan je pokazatelj. Konačna vrijednost od 0,729 na 250. epohi demonstrira da je model razvio sposobnost precizne detekcije čak i kada se zahtijeva vrlo visoko podudaranje sa stvarnim lokacijama.

6. DETEKCIJA BESPILOTNIH LETJELICA NA VIZUALNIM SNIMKAMA

Nakon kreiranog programskog koda (modela) za detekciju bespilotnih letjelica na snimkama, kroz model su provučene snimke napravljene na kampusu Borongaj. Model je uspio detektirati bespilotnu letjelicu na 1037 snimke od ukupno 2148, dok na preostalim snimkama detekcija nije bila uspješna, odnosno bespilotna letjelica je na nekim snimkama krivo detektirana i zamijenjena drugim objektom. Kako bi se nadoknadili nedostaci automatske detekcije i osigurala točna identifikacija bespilotne letjelice na svim snimkama u vidljivom dijelu spektra, one problematične obrađene su ručno pomoću platforme *Roboflow*.

Roboflow predstavlja specijaliziranu internetsku platformu namijenjenu cjelovitom upravljanju i pripremi podataka za treniranje modela. Platforma integrira sve faze rade – od učitavanja i strukturiranja slika, preko preciznog označavanja objekata do izvoza pripremljenih podataka u formatu kompatibilnim s odabranim modelom. Na taj način eliminira potrebu za korištenjem više različitih alata te značajno ubrzava i pojednostavljuje proces pripreme podataka. Rad u *Roboflow*-u započinje učitavanjem skupa snimaka u projekt. Slijedi proces anotacije, odnosno označavanja objekata unutar pojedinačnih kadrova. Osim osnovnog označavanja *Roboflow* nudi napredne mogućnosti obrade snimaka poput promjene njihovih dimenzija, rotacije, zamućenja i prilagodbe kontrasta. Ove funkcije na umjetan način povećavaju raznolikost skupa podataka bez potrebe za dodatnim snimanjima. Kada je obrada dovršena, skup podataka je spreman za izvoz u format pogodan za treniranje YOLO modela, [13].

Tijekom detekcije primijećeno je da model nije uspio detektirati bespilotnu letjelicu u određenim položajima i kutovima poput pozicije „pod nož“. Također, pozadina poput drveća bila je problematična za detekciju bespilotne letjelice. Snimke s bespilotnom letjelicom u takvim položajima i s teže raspoznatljivom pozadinom prebačene su na platformu *Roboflow* gdje su ručno označene.


Zbog velikog broja snimki, skup podataka vizualnih snimki bio je organiziran u sedam odvojenih mapa od kojih je svaka mapa sadržavala nekoliko stotina različitih snimaka, čime se olakšala preglednost i raspodjela posla označavanja snimki te je omogućeno sustavno praćenje napretka u označavanju.

Tijekom procesa označavanja vizualnih snimki svaki kadar je bio pregledan, a bespilotne letjelice su ručno označene *bounding box*-ovima s ciljem precizne identifikacije njegovog položaja i veličine. Pažnja je posvećena jasnoći obrisa bespilotne letjelice, kontrastu s pozadinom te eventualnim preklapanjima s drugim objektima na snimci.

U slučajevima gdje je bespilotna letjelica bila vrlo udaljena, djelomično zaklonjena, slabo kontrastna potrebno je bilo dodatno povećati pažnju prilikom označavanja. Isto vrijedi i za zahtjevne vizualne pozadine, poput vegetacije ili građevina. Stoga je bilo potrebno dodatno uvećati sliku radi lakšeg uočavanja i točnog označavanja bespilotne letjelice.

Pri označavanju snimki trebalo je posvetiti pažnju na to da okvir uvijek bude što manji, ali da istovremeno u potpunosti obuhvati bespilotnu letjelicu bez nepotrebnog okolnog prostora, kako bi se povećala preciznost.

Proces ručne anotacije bio je ključan za stvaranje kvalitetnog skupa podataka za treniranje modela detekcije, pri čemu je dosljednost u označavanju unutar svake mape osigurana pažljivim pristupom i ponovnom provjerom svake oznake. Na slici 10 prikazan je izgled mape na platformi *Roboflow*.



Slika 10. Izgled mape na platformi *Roboflow*

7. KREIRANJE SKUPA PODATAKA S TERMALNIM SNIMKAMA

Sa snimkama označenim u *Roboflow*-u i s onima označenim YOLO modelom, skup podataka iz vidljivog dijela spektra na kojima su bile detektirane bespilotne letjelice bio je kompletan. Taj skup podataka dalje se koristio na sljedeći način:

1. korištenje skupa podataka sa snimkama iz vidljivog dijela spektra za kreiranje skupa podataka sa snimkama iz termalnog dijela spektra
2. treniranje YOLO modela pomoću termalnog skupa podataka u svrhu samostalne detekcije bespilotnih letjelica na termalnim snimkama.

7.1. Pretvaranje koordinata

Budući da se vizualne snimke nisu mogle svesti na rezoluciju termalnih koja je iznosila 640 x 512, korištenjem programa *IrfanView* bile su smanjene s 8000 x 6000 na 640 x 480. To je značilo da se *bounding box* bespilotne letjelice na vizualnoj snimci ne nalazi na istim pikselima kao i na termalnoj. Također, snimke nisu pokrivale identičan prostor te se činilo kao da je termalna snimka uvećana i zahvaća manje stvarne površine u odnosu na vizualnu. Jedan takav primjer prikazan je na slici 11.



Slika 11. Usporedba vizualne i njoj pripadajuće termalne snimke

Svaka snimka imala je svoju pripadajuću istoimenu datoteku s informacijama te poziciji i dimenzijama *bounding box*-a bespilotne letjelice. To su bile tekstualne datoteke od jednog retka s pet elemenata odvojenih razmakom zapisane u formatu *xywhn*. Prvi element označavao je klasu objekta, drugi *x* koordinatu geometrijskog središta *bounding box*-a, treći *y* koordinatu geometrijskog središta, četvrti širinu te peti visinu *bounding box*-a. Slovo *n* u nazivu formata označava da su sve vrijednosti normalizirane, tj. da su vrijednosti koordinata i dimenzija *bounding box*-a zapisane u omjeru s dimenzijama odgovarajućih osi. Primjer jednog zapisa koordinata glasi: 0 0.42890625 0.462890625 0.6796875 0.6015625. Ishodišni piksel (0,0) nalazi se u gornjem lijevom kutu snimke.

Isprobani su bili brojni načini određivanja funkcije ovisnosti koordinata na termalnoj o koordinatama na vizualnoj. Jedan način bio je dobivanje koeficijenta proporcionalnosti dijeljenjem dimenzija za pojedine osi te dodavanjem ili oduzimanjem vrijednosti kako bi se pogodila točna pozicija bespilotne letjelice. Drugi način bio je određivanje dviju fiksnih točaka vidljivih na obje snimke, očitavanje njihovih koordinata na snimkama te pretpostavljanje linearne ovisnosti i računanja dviju jednadžbi s dvije nepoznanice. Ta dva pristupa nisu davala zadovoljavajuće rezultate jer bi u većini slučajeva *bounding box* na termalnoj snimci bio ili pomaknut u jednu stranu ili nedovoljno širok ili visok.

Kao najbolja, izabrana je treća metoda pretvorbe koordinata. Uvidom u otprilike pet slika zaključeno je da lijevi rub termalne snimke odgovara 120. pikselu vizualne snimke, a gornji rub termalne odgovara tek 76. pikselu. Također je primijećeno da širina termalne snimke odgovara širini od 432 piksela na vizualnoj, a visina termalne snimke 342 piksela. Za normaliziranje koordinata korištene su jednadžbe:

$$x_{term} = \frac{x_{viz} \times 640 - 120}{432}$$

$$y_{term} = \frac{y_{viz} \times 480 - 76}{342}$$

gdje su:

x_{term} – normalizirana *x* koordinata geometrijskog središta *bounding box*-a na termalnoj snimci

x_{viz} – normalizirana *x* koordinata geometrijskog središta *bounding box*-a na vizualnoj snimci

y_{term} – normalizirana y koordinata geometrijskog središta *bounding box*-a na termalnoj snimci

y_{viz} – normalizirana y koordinata geometrijskog središta *bounding box*-a na vizualnoj snimci.

Za dimenzije *bounding box*-ova korištene su formule:

$$w_{term} = \frac{w_{viz} \times 640}{432}$$

$$h_{term} = \frac{h_{viz} \times 480}{342}$$

gdje su:

w_{term} – normalizirana širina *bounding box*-a na termalnoj snimci

w_{viz} – normalizirana širina *bounding box*-a na vizualnoj snimci

h_{term} – normalizirana visina *bounding box*-a na termalnoj snimci

h_{viz} – normalizirana visina *bounding box*-a na vizualnoj snimci.

Kod 3 pokazuje konačne formule za transformaciju koordinata zapisane u programskom jeziku *Python*.

```
#računanje termalnih koordinata
t_x = (v_x * 640 - 120) / 432
t_y = (v_y * 480 - 76) / 342
t_w = (v_w * 640) / 432
t_h = (v_h * 480) / 342
```

Kod 3. Preračunavanje koordinata s vizualnih snimki u one na termalnim

Te jednadžbe davale su točnost od ± 5 piksela čime je modeliranje ovisnosti koordinata i dimenzija završilo. Jednom kad su sve formule bile dobivene krenulo se u izradu *Python* koda koji bi automatizirao taj proces te pretvorio ukupno 2144 vizualnih

koordinata u termalne. Ideja je bila pristupiti tekstualnim datotekama s koordinatama iz vizualnih snimki, povući iz njih četiri vrijednosti, obaviti matematičku pretvorbu, kreirati nove tekstualne datoteke istog imena kao i pripadajuće termalne snimke te u njih zapisati rezultate. Cijeli kod dobivanja novih koordinata prikazan je u prilogu 1. na kraju izvještaja. Posljednji dio koda služio je za crtanje novonastalih *bounding box*-ova na termalnim snimkama radi provjere izračuna.

Ovime je bila završena prva verzija skupa podataka s termalnim snimkama. Nju je trebalo poboljšati jer osmišljena formula ipak nije bila savršena. Unatoč svim naporima točna ovisnost između koordinata nije pronađena. Postojali su još i drugi promjenjivi parametri koji nisu uzeti u obzir prilikom matematičkog modeliranja.

7.2. Dorađivanje skupa podataka u *Roboflow*-u


Budući da dobivene formule za izračun koordinata *bounding box*-ova bespilotnih letjelica na termalnim snimkama nisu uvijek točno ili dovoljno precizno označavale bespilotnu letjelicu, bilo je potrebno dodatno provjeriti sve anotirane snimke. Pretvorba koordinata s vizualnih snimki na termalne trebala je osigurati da se pozicija bespilotnih letjelica na termalnim snimkama točno označi, no u praksi te pretvorbe nisu uvijek bile dovoljno precizne. Pogreške su se pojavljivale zbog razlika u kutu snimanja i zbog vremenskog razmaka među kadrovima. Zbog toga su se sve termalne snimke, koje su bile označene, morale ručno pregledati u *Roboflow*-u. U svakom slučaju gdje *bounding box* nije precizno obuhvaćao bespilotnu letjelicu, okvir je bio ručno prilagođen, tj. za svaku sliku je procijenjeno treba li okvir pomaknuti, skalirati, potpuno ukloniti i dodati novi, kako bi obuhvatio točnu poziciju bespilotne letjelice.

Uspješnost modela za detekciju objekata nije određena samo strukturom i načinom funkcioniranja modela već u velikoj mjeri ovisi o kvaliteti i pažljivo osmišljenoj strategiji pripreme skupa podataka. U praksi se kao standardan postupak primjenjuje podjela podataka na tri funkcionalno odvojena dijela: skup za treniranje, validacijski skup i skup za testiranje. Skup za treniranje koji u pravilu obuhvaća između 70 – 80 % dostupnih podataka koristi se za učenje modela i oblikovanje njegovih sposobnosti prepoznavanja. Validacijski skup u rasponu od 15 – 20 % od velike je važnosti tijekom same faze treniranja jer omogućuje provjeru učinkovitosti na podacima s kojima se

model nije ranije susreo. Time se stvara prostor za pravovremeno uočavanje pojave pretreniranosti. Skup za testiranje koji čini preostalih 10 – 15 % podataka nikada ne sudjeluje ni u procesu treniranja ni u validaciji već služi isključivo za konačnu i nepristranu procjenu sposobnosti modela. Upravo ovaj skup pruža najpouzdaniju sliku o tome kako će model funkcionirati u stvarnim uvjetima i s potpuno novim podacima, [14].

Također, skup podataka je u *Roboflow*-u podijeljen u tri mape. Mapa za treniranje u kojoj je bilo 70 % snimki, mapa za validaciju s 20 % snimki i mapa za testiranje s preostalih 10 %.

Sve snimke mogle su se i ručno označiti čime bi se izbjeglo preračunavanje koordinata, ali *Python* kod uvelike je ubrzao taj proces. Na slici 12 prikazano je sučelje platforme *Roboflow* u trenutku ispravnog označavanja bespilotne letjelice na termalnoj snimci.



Slika 12. Sučelje u *Roboflow*-u za označavanje objekata

Navedena faza rada bila je važna za osiguravanje kvalitete podataka, tj. za povećanje pouzdanosti skupa podataka i poboljšanje performansi budućeg detekcijskog modela. Neispravne ili nekonzistentne oznake negativno bi utjecale na treniranje modela, što bi dovelo do smanjene točnosti u stvarnim uvjetima. Ručnom korekcijom osigurana je veća točnost budućih detekcija na termalnim snimkama te je kreiran kvalitetan skup podataka spreman za daljnje korištenje primjenu u treniranju detekcijskog modela.

8. YOLO MODEL ZA TERMALNE SNIMKE


Nakon prikupljanja i pripreme skupa termalnih snimaka, pristupilo se treniranju YOLO modela kako bi bio mogao samostalno prepoznavati bespilotne letjelice na tim snimkama. Termalne infracrvene snimke snimljene bespilotnim letjelicama predstavljaju poseban izazov za detekciju objekata jer su često niske rezolucije, imaju ograničene informacije o teksturi te je prisutan značajan šum. Takvi uvjeti otežavaju primjenu standardnih metoda detekcije koje se temelje na bojama i vizualnim detaljima što naglašava važnost korištenja specijaliziranih algoritama poput YOLO modela. Za razliku od metoda koje se oslanjaju na vidljive značajke objekata, YOLO modeli u termalnom spektru prepoznaju objekte prema njihovom toplinskom otisku koje se očituje u nijansama sive boje. Slojevi konvolucijske mreže uče identificirati karakteristične obrasce toplinskog otiska koji upućuju na prisutnost bespilotne letjelice, uključujući toplinu motora i elektroničkih komponenti. Zahvaljujući toj sposobnosti, model može pouzdano detektirati bespilotne letjelice čak i kada su snimke niske kvalitete ili kada vidljivi dio spektra ne pruža dovoljno informacija za preciznu identifikaciju objekata. Primjena YOLO modela na termalnim snimkama pokazuje kako se napredne metode strojnog učenja mogu prilagoditi specifičnim izazovima termalne detekcije, kombinirajući brzinu i preciznost, [15].

8.1. Treniranje 1. modela


U prvom treniranju korišten je model koji je već bio istreniran na vizualnim slikama kako bi se dodatno poboljšao. Treniranje se provodilo na izvornih 1504 snimke, 100 epoha, korištenjem vanjske grafičke kartice te je trajalo približno 5 sati. Kod za pokretanje takvog treniranja nalazi se u kodu 4, a na grafovima 7 – 9 su prikazani rezultati treniranja modela.

```
from ultralytics import YOLO
model = YOLO("D/ZIN projekt
2025/runs/detect/train14/weights/last.pt")
results = model.train(data="D:/ZIN projekt 2025/termalni
dataset/data.yaml", epochs=100, imgsz=640, batch=0.9, device=0)
```


Kod 4. Pokretanje treniranja YOLO modela na termalnim snimkama



Graf 7. Rezultati funkcija gubitka (*train*) prvog treniranje na termalnim snimkama



Graf 8. Rezultati funkcija gubitka (*val*) prvog treniranja na termalnim snimkama



Graf 9. Rezultati funkcija metrika prvog treniranja na termalnim snimkama

Izgled funkcija gubitaka *train/box_loss*, *train/cls_loss* i *train/dfl_loss* je bio očekivan, tj. padajući, no na validacijskom setu primijećen je njihov porast poslije otprilike 50. epohe što znači da je došlo do pretreniranosti modela.

Pretreniranost je situacija u kojoj model predobro nauči podatke na kojima je treniran, ali ne prenosi to znanje na nove, nepoznate podatke. Neki od razloga mogu biti [16]:

- premali skup podataka
- previše epoha treniranja
- manjak augmentacije podataka, tj. raznolikosti
- prevelika kompleksnost modela – korištenje prevelike verzije YOLO-a.


Budući da prvo treniranje nije ostvarilo željene rezultate, krenulo se na sljedeće.

8.2. Treniranje 2. modela

Kao drugi pokušaj treniranja korištene su neke od metoda kako smanjiti učinke pretreniranosti. Povećan je skup podataka pomoću već gotovih funkcija u *Roboflow*-u za augmentaciju, dok su ostali parametri u pozivu naredbe ostali isti. Korišteni su [17]:


- preokretanje (engl. *flip*) – horizontalno i vertikalno
- rotacija za 90 stupnjeva (engl. *90° rotate*) u smjeru kazaljke na satu i suprotno
- manja rotacija (engl. *rotation*) u intervalu od –15 do 15 stupnjeva
- svjetlina (engl. *brightness*) u intervalu od –20 % do 20 %
- ekspozicija (engl. *exposure*) u intervalu od –10 % do 10 %
- zamućivanje (engl. *blur*) do 2,5 px.

Na slici 13 prikazane su neke od korištenih augmentacija na snimkama.




Slika 13. Primjer augmentacije na snimkama


Set za treniranje time se povećao na 4512 snimki. Dobiveni rezultati nakon treniranja s novim skupom podataka nalaze se na grafovima 10 – 12.



Graf 10. Rezultati funkcija gubitka (*train*) drugog treniranje na termalnim snimkama



Graf 11. Rezultati funkcija gubitka (*val*) drugog treniranje na termalnim snimkama



Graf 12. Rezultati funkcija metrika drugog treniranja na termalnim snimkama

Nakon drugog treniranja vidljivo je da su se sva četiri rezultata metrike poboljšala, ali na funkcijama gubitka nema značajnijih pomaka. I dalje je vrlo izražena pretreniranost što se vidi na funkcijama gubitka validacijskog seta te se jedino na parametru *val/box_loss* nazire poboljšanje odnosno blaži porast vrijednosti u višim epohama.

8.3. Treniranje 3. modela

Za treći pokušaj treniranja i drugi pokušaj poboljšavanja performansi modela dodatno je nabavljen plan *Roboflow* „Basic“ u vrijednosti od 65 dolara, kojim je povećan skup podataka na 7520 snimki za treniranje, tj. 8160 snimaka ukupno. Uz prethodno navedenu augmentaciju, dodana je sljedeća [17]:

- obrezivanje (engl. *crop*) s maksimalnim uvećanjem od 25 %
- šum (engl. *noise*) – do 1,52 % piksela.

Također, pri pozivu naredbe za treniranje modela dodan je argument *dropout* koji je jedan od preporučenih metoda sprječavanja pretreniranosti sa stanice Ultralytics-a, [18].


Dropout je tehnika regularizacije koja sprječava pretreniranost na način da na svakoj epohi nasumično izostavi ili isključi zadani postotak neuronske mreže te time natjera model da uči robusnije značajke koje nisu povezane s određenim neuronima. U trećem treniranju *dropout* vrijednost postavljena je na 0,2, [18].

Kao zadnja izmjena, promijenjen je model koji se trenirao. Prva dva treniranja vršila su se na modelu koji je već bio istreniran vizualnim snimkama, a treće treniranje sprovelo se na osnovnom „pretrained“ modelu YOLO11x.pt što je vidljivo u kodu 5. Takva odluka donesena je jer je postojala mogućnost da je model, treniran na vizualnim snimkama, već preistreniran te bi bilo bolje započeti iznova.


```
from ultralytics import YOLO
model = YOLO("yolo11x.pt")
results = model.train(data="D:/ZIN projekt 2025/termalni
dataset/data.yaml", epochs=100, imgsz=640, batch=0.9, device=0,
dropout=0.2)
```

Kod 5. Treće treniranje na termalnim snimkama


Rezultati trećeg treniranja prikazani su grafovima 13 – 15.



Graf 13. Rezultati funkcija gubitka (*train*) trećeg treniranje na termalnim snimkama



Graf 14. Rezultati funkcija gubitka (*val*) trećeg treniranje na termalnim snimkama



Graf 15. Rezultati funkcija metrika trećeg treniranja na termalnim snimkama

Treće treniranje bilo je uspješnije od prethodnog. Iako pretreniranost modela još uvijek postoji, na grafovima su vidljivi pomaci usmjereni prema uklanjanju pretreniranosti.


8.4. Treniranje 4. modela

Kao posljednji pokušaj poboljšavanja performansi modela i još uspješnije detekcije bespilotnih letjelica na termalnim snimkama odlučeno je povećati skup podataka, no ovaj put ne umjetnim nego stvarnim putem. Provedeno je dodatno snimanje na kampusu Borongaj pod dnevnim svjetlom, ali i po noći gdje su napravljene još 304 snimke. Tim dodatkom povećana je raznolikost skupa podataka jer objekti u prostoru nemaju jednake termalne otiske po danu i po noći. Također, detaljnim uvidom u platformu *Roboflow* i termalni skup podataka na njoj, otkrivena je mana programa te je otklonjeno 514 pozadinskih snimaka koje se nisu uza sebe imale povezanu informaciju o koordinatama *bounding box*-eva. Te snimke iznova su pravilno označene te pridodane u skup podataka pod mapu za treniranje.


Sve prethodne augmentacije i parametri treniranja ostali su isti te su na to nadodane još dvije augmentacije [17]:

- smicanje (engl. *shear*) u intervalu od ± 10 stupnjeva horizontalno i ± 10 stupnjeva vertikalno
- zasićenost (engl. *saturation*) između -25% i 25% .


Ukupan broj snimki koji se koristio za zadnje treniranje iznosio je 8585, a cijeli skup podataka sastojao se od 9316 snimki. Rezultati posljednjeg treniranja na najnovijem termalnom skupu podataka prikazani su na grafovima 16 – 18.



Graf 16. Rezultati funkcija gubitka (*train*) četvrtog treniranje na termalnim snimkama



Graf 17. Rezultati funkcija gubitka (val) četvrtog treniranje na termalnim snimkama



Graf 18. Rezultati funkcija metrika četvrtog treniranja na termalnim snimkama

Na zadnjem treniranju najmanje je izražena pretreniranost što je vidljivo iz grafa funkcije gubitka (val), a graf s funkcijama metrike pokazuje najveće vrijednosti do sada.

9. ANALIZA

U tablicama 2 i 3 prikazane su karakteristične vrijednosti deset parametara nakon svakog od četiri treniranja.

Tablica 2. Vrijednosti funkcija gubitaka na setu za treniranje i metrike na kraju pojedinog treniranja (zeleno su osjenčane vrijednosti najboljih performansi modela)

	Nakon 1. treniranja (100 epoha)	Nakon 2. treniranja (100 epoha)	Nakon 3. treniranja (100 epoha)	Nakon 4. treniranja (100 epoha)
<i>Train/box_loss</i>	0,983	0,996	0,995	1,001
<i>Train/cls_loss</i>	0,404	0,416	0,416	0,503
<i>Train/df_l_loss</i>	1,187	1,280	1,283	1,278
<i>Metrics/precision(B)</i>	0,963	0,969	0,964	0,979
<i>Metrics/recall(B)</i>	0,959	0,973	0,948	0,980
<i>Metrics/mAP50(B)</i>	0,974	0,981	0,974	0,985
<i>Metrics/mAP50-95(B)</i>	0,548	0,563	0,569	0,565

Uočljivo je da su funkcije gubitka u setu za treniranje dosegle minimalne vrijednosti već nakon prvog treniranja što znači da je ono bilo dovoljno da model nauči raspoznavati bespilotne letjelice na tim konkretnim slikama. Za parametre metrike bila su potrebna četiri treniranja s augmentiranim skupom podataka kako bi dostigle svoj maksimum. Parametar *metrics/mAP50-95(B)* nakon trećeg je treniranja dosegao najvišu vrijednost.

Tablica 3. Vrijednosti funkcija gubitaka na validacijskom setu (najniža vrijednost i vrijednost na kraju treniranja – 100. epoha; zeleno su osjenčane vrijednosti najboljih performansi modela)

	1. treniranje		2. treniranje		3. treniranje		4. treniranje	
	min.	100. epoha	min.	100. epoha	min.	100. epoha	min.	100. epoha
<i>Val/box_loss</i>	1,573	1,647	1,516	1,618	1,571	1,622	1,547	1,604
<i>Val/cls_loss</i>	0,572	0,592	0,529	0,542	0,527	0,538	0,488	0,503
<i>Val/dfl_loss</i>	1,660	1,829	1,712	1,901	1,534	1,819	1,622	1,777

Funkcije gubitaka na validacijskom set, one koje su ukazivale na pretreniranost te zbog kojih su se i ponavljala treniranja, postižu najbolje rezultate nakon četvrtog treniranja i svih njegovih izmjena. Što se tiče pretreniranosti definitivno je četvrto treniranje najviše pomoglo te je pojačana generalizacija modela za nove podatke i snimke bespilotnih letjelica. Vjerojatno je, da bi se daljnjom primjenom augmentacijskih tehnika, povećavanjem *dropout* vrijednosti ili čistim povećavanjem broja snimaka u skupu podataka dobili još niži iznosi funkcija gubitaka, a i bolje vrijednosti funkcija metrika koje bi naravno rasle. Vrijednosti metrike nisu puno rasle nakon uzastopnih treniranja, ali svako i najmanje poboljšanje znači puno za točnost detekcije objekata.

9.1. Validacija modela

Nakon četvrtog treniranja provedena je validacija dobivenog modela na potpuno nezavisnom skupu termalnih snimaka naziva „Drone-Detection“ koji je pronađen i preuzet s platforme *Roboflow*, [19]. Skup se sastoji od 503 termalne snimke. U tablici 4 prikazane su vrijednosti funkcija metrike dobivene validacijom.

Tablica 4. Usporedba konačnih vrijednosti funkcija metrike nakon treniranja i nakon nezavisne validacije


	Nakon treniranja	Nakon validacije
<i>Metrics/precision(B)</i>	0,979	0,901
<i>Metrics/recall(B)</i>	0,980	0,826
<i>Metrics/mAP50(B)</i>	0,985	0,853
<i>Metrics/mAP50-95(B)</i>	0,565	0,409

Iz tablice je vidljivo da su iznosi funkcija metrike manji na nezavisnom validacijskom setu nego na validacijskom setu nakon četvrtog treniranja. To je zato što su snimke za validaciju iz snimljenog skupa podataka sličnije onima na kojima se model trenirao nego one iz nezavisnog skupa podataka. Ostvarene vrijednosti na nezavisnom skupu podataka vrlo su uspješne jer uspoređujući ih s vrijednostima metrike koje postižu neki drugi modeli kao što su *Faster R-CNN* ili *Swin Transformer*, vidljivo je da je dobiveni model kompetentan u industriji detekcije bespilotnih letjelica. Generalno, vrijednosti preko 0,8 za preciznost, odziv i mAP50 smatraju se odličnim, a za mAP50-95 već od 0,4. Rezultati na nezavisnom validacijskom setu su stvarni pokazatelj uspješnosti dobivenog modela, [20].


Idući parametar performansi modela koji je promatran jest vrijednost $F1$. To je metrika koja kombinira preciznost i odziv u jedan pokazatelj te predstavlja njihovu harmonijsku sredinu. Budući da se radi o harmonijskoj sredini, visok $F1$ moguće je postići jedino u slučaju kada su i preciznost i odziv visoki. $F1$ se računa po sljedećoj formuli [11]:

$$F1 = 2 \times \frac{\text{preciznost} \times \text{odziv}}{\text{preciznost} + \text{odziv}}$$

Najbolji $F1$ svaki model postiže za određeni stupanj pouzdanosti (engl. *confidence*). Grafovi 19 i 20 prikazuju ovisnosti vrijednosti $F1$ o stupnju pouzdanosti za dobiveni model odmah nakon treniranja te na nezavisnom validacijskom setu, a označeni su i maksimumi funkcija.




Graf 19. Ovisnost $F1$ o pouzdanosti za dobiveni model odmah nakon treniranja



Graf 20. Ovisnost $F1$ o pouzdanosti za dobiveni model na nezavisnom validacijskom setu


Funkcija $F1$ u prvom slučaju postiže svoj maksimum pri faktoru pouzdanosti od 0,40 te iznosi 0,98, dok se na nezavisnom validacijskom setu taj maksimum dostiže pri faktoru pouzdanosti od 0,37 te iznosi 0,86. Faktor pouzdanosti je parametar koji se ručno podešava prije izvršavanja detekcije objekata kako bi model znao koliko minimalno korisnik od njega želi da bude siguran da se unutar označenog područja zaista nalazi traženi objekt, a izražava se u rasponu od 0 do 1. Postavljanjem manjeg faktora pouzdanosti povećava se odziv detekcije, ali se smanjuje njena preciznost, dok je kod postavljanja većeg faktora pouzdanosti suprotno. Iz grafova je također vidljivo da povećavanje faktora pouzdanosti do 0,70 na grafu 19 te do 0,75 na grafu 20, neće značajno narušiti rezultat $F1$. To znači da model daje stabilne rezultate za različite faktore pouzdanosti jer odnos preciznosti i odziva ostaje gotovo nepromijenjen.

Dobiveni rezultat od 0,86 smatra se visokim što znači da model učinkovito detektira objekte te u isto vrijeme minimizira netočne detekcije. U ovoj validaciji pod netočne detekcije bespilotne letjelice ubrajaju se one snimke na kojima nije pronađena niti jedna bespilotna letjelica kao i snimke na kojima je pronađeno više od jedne bespilotne letjelice. Jedan takav primjer prikazan je na slici 14, a decimalni broj pored riječi „drone“ predstavlja vjerojatnost koliko je model siguran da se na označenom mjestu nalazi bespilotna letjelica.




Slika 14. Primjer netočne (dvostruke) detekcije iste bespilotne letjelice

Objedinjeni prikaz svih mogućih ishoda detekcija nakon treniranja i nakon nezavisne validacije vidljiv je na slikama 15 i 16 u matricama konfuzije. To je evaluacijska tehnika koja predstavlja matricu dimenzije 2 x 2. Na stupcima ima istinite vrijednosti, a na redcima predviđene vrijednosti od strane modela. Vrijednosti unutar matrice su frekvencije pojavljivanja svih kombinacija ishoda, [21, 22].



Slika 15. Matrica konfuzije za dobiveni model odmah nakon treniranja



Slika 16. Matrica konfuzije za dobiveni model nakon nezavisne validacije

U matricama konfuzije četiri kvadranta predstavljaju četiri mogućnosti za točnu ili netočnu detekciju:

1. *TP* (engl. *true positive*) – broj ispravno detektiranih objekata (*gore lijevo*)
2. *FP* (engl. *false positive*) – broj neispravno detektiranih objekata (*gore desno*)
3. *FN* (engl. *false negative*) – broj nedetektiranih objekata (*dolje lijevo*)
4. *TN* (engl. *true negative*) – broj ispravno prepoznatih pozadina (*dolje desno*).

Četvrti kvadrant zapravo predstavlja sva područja za koja je model ispravno predvidio da ne predstavljaju bespilotnu letjelicu, a budući da takvih ima beskonačno mnogo i ti slučajevi nisu značajni za analizu, donji desni kvadrant ostavljen je prazan, tj. $TN = 0$.

Iz slike 15 vidljivo je da je broj točnih detekcija bespilotnih letjelica na snimljenom skupu podataka nakon treniranja iznosio 482 (*TP*). 7 puta model nije uspio detektirati bespilotnu letjelicu (*FN*), a 10 puta ju je detektirao na mjestu gdje nije postojala (*FP*).

Slika 16 prikazuje kako je model na nezavisnom validacijskom skupu podataka točno detektirao 430 bespilotnih letjelica (*TP*). 75 bespilotnih letjelica model nije uspio detektirati (*FN*), a 57 puta ih je pogrešno detektirao (*FP*). Iz dobivenih vrijednosti računa se jedna od osnovnih metoda za evaluaciju rada modela koja se naziva točnost.

Točnost je metoda za procjenu uspješnosti modela. Ona pokazuje koliki postotak predikcija modela odgovara stvarnim rezultatima, odnosno mjeri udio ispravnih predikcija u odnosu na ukupan broj predikcija.

$$Točnost = \frac{Broj\ ispravnih\ predikcija}{Ukupan\ broj\ predikcija}$$

Matematički se može izraziti formulom:

$$Točnost = \frac{TP + TN}{TP + TN + FP + FN}$$

Prema podacima iz matrice konfuzije za dobiveni model odmah nakon treniranja model točnost se izračunava:

$$Točnost = \frac{482}{482 + 10 + 7} = 0,966 \text{ (96,6 \%)}$$

Na temelju podataka dobivenih za model nakon nezavisne validacije točnost se izračunava:

$$Točnost = \frac{430}{430 + 57 + 75} = 0,765 \text{ (76,5 \%)}$$

Zbog svoje jednostavnosti i lakoće razumijevanja često se koristi kao pokazatelj opće učinkovitosti modela osobito kod klasifikacijskih zadataka. Takav pristup omogućava brz prikaz performansi modela prije nego što se pristupi detaljnijoj analizi. Međutim, iako daje osnovnu informaciju o tome koliko je model točan, sama točnost ne pruža informacije o tome kako se model ponaša kod pojedinih klasa. Zbog toga se točnost često kombinira s drugim metrikama poput preciznosti i odziva kako bi se dobile cjelovitije i pouzdanije informacije o performansama modela, [21].

9.2. Primjena modela

Na slici 17 prikazana je detekcija objekata korištenjem osnovnog „pretrained“ YOLO11x modela na dvije termalne snimke iz snimljenog skupa podataka. Takav model je na tom skupu podataka prepoznavao četkice za zube, automobile, vlakove, hladnjake, sudopere, ljude, prometne znakove, brodove, šalice, boce, avione i ptice te gotovo ništa nije bilo točno detektirano.



Slika 17. Detekcija objekata korištenjem početnog YOLO11x.pt modela


Primjeri točnih detekcija novonastalog modela na termalnim snimkama u jednostavnijim uvjetima prema onim složenijim, na kojima je i ljudskom oku vrlo teško pronaći bespilotnu letjelicu, prikazani su tim redoslijedom na slikama 18 – 21.



Slika 18. Primjer točne detekcije bespilotne letjelice (1/4)



Slika 19. Primjer točne detekcije bespilotne letjelice (2/4)



Slika 20. Primjer točne detekcije bespilotne letjelice (3/4)



Slika 21. Primjer točne detekcije bespilotne letjelice (4/4)

Uspoređujući zadnje nastali model s početnim YOLO11x.pt modelom iz kojeg je nastao, jasan je velik napredak u detekciji objekata. Činjenica da je iz jednog takvog slabog modela nastao novi model koji detektira bespilotne letjelice na termalnim snimkama s preciznošću od 0,901 te odzivom od 0,826 i više govori o velikoj uspješnosti skupa podataka koji je nastao kao rezultat ovog projekta.

Ovakve značajke čine model podobnim za primjenu u važnim sustavima kao što su sustavi zaštite objekata ili granica putem videonadzora, autonomna vozila, sustav za izbjegavanje sudara bespilotnih letjelica u zraku tijekom noćnih operacija ili zrakoplovna izviđanja iz zraka u svrhu znanstvenih ili drugih istraživanja, [11].

Sigurnost zračnog prometa jedna je od najbitnijih primjena modela detekcije bespilotnih letjelica. U lipnju 2024. Hrvatska agencija za civilno zrakoplovstvo objavila je priopćenje o opasnosti od povećanog broja letačkih operacija bespilotnih letjelica u blizini dvije hrvatske zračne luke Split i Dubrovnik. U razdoblju od 29. svibnja – 13. lipnja 2024. bila su zabilježena tri protupravna približavanja bespilotnih letjelica putničkim zrakoplovima. Agencija je izrazila zabrinutost jer je tijekom cijele 2023. godine zabilježeno svega 7 izvješća vezanih uz neovlašteno letenje bespilotnim letjelicama. Drugi primjer ovakvih radnji je iz prosinca 2018. kada je više neovlaštenih bespilotnih letjelica letjelo u blizini zračne luke London Gatwick. Aerodromske vlasti bile su prisiljene obustaviti operacije na nekoliko dana zbog potencijalne štete koje su mogle nanijeti zrakoplovima. Otkazano je bilo gotovo 1000 letova, pogođeno oko 140.000 putnika kojima su izazvane velike neugodnosti, a gubitak prihoda za zrakoplovne kompanije iznosio je otprilike 5 milijuna funti. U Republici Hrvatskoj kazne za neovlašteno letenje bespilotnim letjelicama propisane su Zakonom o zračnom prometu, [23, 24, 25].

Na temelju dobivenih rezultata validacije modela ovaj rad ostavlja prostor za daljnja poboljšanja. Povećanjem raznolikosti termalnog skupa podataka i korištenjem naprednijih verzija YOLO modela moguće je postići još veću produktivnost i primjenjivost modela. Na taj način buduća istraživanja mogu dodatno unaprijediti rezultate i otvoriti mogućnost šire upotrebe razvijenog modela.

Model za detekciju bespilotnih letjelica na termalnim snimkama te vizualni i termalni skupovi podataka nastali u sklopu ovog istraživanja objavljeni su javno na digitalnoj platformi za pohranu i dijeljenje znanstvenih i istraživačkih podataka *Zenodo*. Takvi podaci, posebice termalni, nisu u dovoljnoj mjeri dostupni u javnim izvorima. Otvorenim pristupom ovim skupovima podataka doprinosimo unaprjeđenju postojećih modela te potičemo daljnja istraživanja u ovom području, [26].

10. ZAKLJUČAK

Cilj rada bio je kreirati model za detekciju bespilotnih letjelica na termalnim snimkama. U tu svrhu korišteno je šest različitih bespilotnih letjelica te se tijekom tri dana snimanja napravio prikladan termalni skup podataka potreban za treniranje YOLO modela za detekciju. Također, bilo je potrebno umanjiti broj ručnih označavanja bespilotnih letjelica na termalnim snimkama te je zato prvo kreiran vizualni skup podataka, a potom su oznake prebačene na termalne snimke. Dobiveni model ostvario je uspjeh po sljedećim performansama: *metrics/precision* – 0,901, *metrics/recall* – 0,826, *metrics/mAP50* – 0,853, *metrics/mAP50-95* – 0,409, *F1* rezultat od 0,86 te točnost od 0,765. Takvi rezultati postignuti su na validaciji modela na nezavisnom termalnom skupu podataka.

U radu je prikazan cjelovit proces razvoja YOLO modela za detekciju bespilotnih letjelica na termalnim snimkama, s posebnim naglaskom na praktične izazove i rješenja koja su bila potrebna za ostvarenje postavljenih ciljeva. Razvijeni model predstavlja odgovor na uočene nedostatke klasičnih vizualnih metoda detekcije te nudi pouzdano rješenje u situacijama smanjene vidljivosti, poput noći ili magle. Kroz jasno definiranu metodologiju rad pokazuje da primjena suvremenih tehnologija i inovativnih pristupa rezultira modelom visoke preciznosti i učinkovitosti u području sigurnosne i civilne primjene.

Važan naglasak stavljen je na fazu prikupljanja snimaka. Snimanja su provedena u različitim vremenskim uvjetima i s više tipova bespilotnih letjelica, čime je stvoren raznolik i reprezentativan skup podataka. Noćno snimanje pokazalo se posebno korisnim jer je omogućilo jasno uočavanje bespilotnih letjelica u uvjetima potpune tame. Na taj način oblikovan je skup podataka koji je u velikoj mjeri pridonio pouzdanosti modela i njegovoj sposobnosti da detektira bespilotne letjelice u različitim scenarijima. Velik doprinos radu bio je razvoj metode za pretvorbu koordinata između vizualnih i termalnih snimki. Iako je u početku korišten matematički model, praksa je pokazala da su nužne i dodatne korekcije te ručna provjera kako bi se osigurala točnost anotacija. Kreirani termalni skup podataka bio je temelj za treniranje YOLO modela, a njegova kvaliteta bila je presudna za kasnije rezultate. Provedena treniranja jasno su pokazala da YOLO model, uz dobro strukturiran i obogaćen skup podataka može s visokom preciznošću i pouzdanošću detektirati bespilotne letjelice u uvjetima

smanjene vidljivosti. Primjenom augmentacije, višestrukim treniranjem i metodama za smanjenje pretreniranosti postignute su stabilne performanse. Skupovi podataka i model za detekciju objavljeni su javno kako bi se koristili u daljnjim istraživanjima.

Dobivene vrijednosti metrika potvrđuju da razvijeni model nudi konkurentna rješenja u odnosu na postojeće modele, poput *Faster R-CNN* i *Swin Transformer*, te da se može primijeniti u različitim praktičnim scenarijima – primjerice u sustavima zaštitnog nadzora objekata ili granica videokamera, osobito u blizini aerodroma. U slučaju potrebe za boljim performansama modela, moguće je izraditi raznolikiji skup podataka termalnih snimki ili koristiti noviju i napredniju verziju YOLO modela. Bepilotne letjelice će zbog svojih karakteristika u budućnosti imati sve širu primjenu u raznim područjima ljudske djelatnosti te će imati značajan ekonomski utjecaj na društvo. Riječ je o industriji koja se ubrzano razvija zbog velike potražnje. Zbog toga je važno kontrolirati takvu vrstu zračnog prometa i staviti sve bepilotne letjelice pod nadzor barem na područjima ograničenog pristupa gdje je povećana potreba za sigurnošću.

ZAHVALE

Najviše zahvaljujemo našem mentoru, izv. prof. dr. sc. tech. Tomislavu Radišiću, na istraživačkoj ideji, stručnom vodstvu i strpljenju. Njegova predanost, povjerenje i konstruktivni savjeti bili su od velike važnosti za uspješnu izradu ovoga rada.

Zahvaljujemo izv. prof. dr. sc. tech. Jurici Ivoševiću na stručnoj podršci tijekom pripremanja bespilotnih letjelica za let i za vrijeme snimanja.

Zahvaljujemo asistentu Patriku Rožiću, univ. mag. ing. aeroing. na brojnim stručnim savjetima i stalnoj podršci tijekom programiranja modela za detekciju bespilotnih letjelica, te izv. prof. dr. sc. Mariju Muštri i asistentu Luki Kramariću, ing. inf. et. comm. techn. na pomoći u snimanju i ustupanju bespilotne letjelice *DJI Inspire 1 v2*.

Zahvaljujemo Zavodu za aeronautiku Fakulteta prometnih znanosti Sveučilišta u Zagrebu na ustupljenim resursima za provedbu eksperimentalnog dijela rada.

LITERATURA

- [1] Andraši P, Radišić T, Muštra M, Ivošević J. Night-time Detection of UAVs using Thermal Infrared Camera. *Transportation Research Procedia*. 2017;28: 183-190. Preuzeto s: <https://doi.org/10.1016/j.trpro.2017.12.184>. [Pristupljeno 20. kolovoza 2025.]
- [2] Chen Y, Sun H, Tian L, Yang Y, Wang S, Wang T. Detecting infrared UAVs on edge devices through lightweight instance segmentation. *PLoS One*. 2025;20(8): 0330074. Preuzeto s: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12360555/> [Pristupljeno 20. kolovoza 2025.]
- [3] Svanström F, Englund C, Alonso-Fernandez F. Real-Time Drone Detection and Tracking With Visible, Thermal and Acoustic Sensors. *2020 25th International Conference on Pattern Recognition (ICPR), 10-15 January 2021, Milan, Italy*. IEEE; 2021. pp. 7265-7272. Preuzeto s: <https://doi.org/10.1109/ICPR48806.2021.9413241>. [Pristupljeno: 21. kolovoza 2025.]
- [4] Wang Y, Chen Y, Choi J, Kuo C-CJ. Towards Visible and Thermal Drone Monitoring with Convolutional Neural Networks. *APSIPA Transactions on Signal and Information Processing*. 2019;8(1): 5. Preuzeto s: <https://doi.org/10.1017/ATSIP.2018.30>. [Pristupljeno: 24. kolovoza 2025.]
- [5] Weather Spark. *Weather History in Zagreb*. Preuzeto s: <https://weatherspark.com/h/d/78960/2025/6/20/Historical-Weather-on-Friday-June-20-2025-in-Zagreb-Croatia> [Pristupljeno: 9. kolovoza 2025.]
- [6] Murat AA, Kiran MS. A comprehensive review on YOLO versions for object detection. *Engineering Science and Technology, an International Journal*. 2025;70: 102161. Preuzeto s: <https://doi.org/10.1016/j.jestch.2025.102161> [Pristupljeno: 8. kolovoza 2025.]
- [7] Gutierrez G, Llerena JP, Usero L, Patricio MA. A Comparative Study of Convolutional Neural Network and Transformer Architectures for Drone Detection in Thermal Images. *Applied Sciences*. 2025;15(1): 109. Preuzeto s: <https://doi.org/10.3390/app15010109> [Pristupljeno: 10. srpnja 2025.]

- [8] Encord. *YOLO Object Detection Guide*. Preuzeto s: <https://encord.com/blog/yolo-object-detection-guide/#:~:text=This%20works%20by%20passing%20the,certain%20cell%20or%20bounding%20box> [Pristupljeno: 10. srpnja 2025.]
- [9] DataCamp. *YOLO Object Detection Explained*. Preuzeto s: https://www.datacamp.com/blog/yolo-object-detection-explained?dc_referrer=https%3A%2F%2Fwww.google.com%2F [Pristupljeno: 12. kolovoza 2025.]
- [10] UAVs Computer Vision Model. Preuzeto s: <https://universe.roboflow.com/uavs-717kv/uavs-vqpqt> [Pristupljeno: 17. ožujka 2025.]
- [11] Ultralytics. *YOLO Performance Metrics – How to Interpret the Intersection over Union (IoU) Value for YOLO11 Object Detection*. Preuzeto s: <https://docs.ultralytics.com/guides/yolo-performance-metrics/#how-do-i-interpret-the-intersection-over-union-iou-value-for-yolo11-object-detection> [Pristupljeno: 10. kolovoza 2025.]
- [12] Drone_07 Computer Vision Model. Preuzeto s: https://universe.roboflow.com/112211/drone_07 [Pristupljeno: 7. travnja 2025.]
- [13] Roboflow. *About Us*. Preuzeto s: <https://roboflow.com/about> [Pristupljeno: 10. kolovoza 2025.]
- [14] Encord. *Training, Validation, Test Split for Machine Learning Datasets*. Preuzeto s: https://encord.com/blog/train-val-test-split/?utm_source=chatgpt.com [Pristupljeno: 16. srpnja 2025.]
- [15] Jiang C, Ren H, Ye X, Zhu J, Zeng H, Nan Y, Sun M, Ren X, Huo HT. Object detection from UAV thermal infrared images and videos using YOLO models. *International Journal of Applied Earth Observation and Geoinformation*. 2022;112(9): 102912. Preuzeto s: <https://doi.org/10.1016/j.jag.2022.102912> [Pristupljeno: 9. lipnja 2025.]
- [16] Ultralytics. *Overfitting*. Preuzeto s: <https://www.ultralytics.com/glossary/overfitting> [Pristupljeno 17. lipnja 2025.]

- [17] Roboflow. *Image augmentation*. Preuzeto s: <https://docs.roboflow.com/datasets/dataset-versions/image-augmentation> [Pristupljeno: 9. lipnja 2025.]
- [18] Redmon J, Divvala S, Girshick R, Farhadi A. *You Only Look Once: Unified, Real-Time Object Detection*. University of Washington; Allen Institute for AI; Facebook AI Research; 2016. Preuzeto s: <https://arxiv.org/pdf/1506.02640> [Pristupljeno: 12. kolovoza 2025.]
- [19] Drones-Detection. Preuzeto s: <https://universe.roboflow.com/insat-e0whu/drones-detection-b8pud/browse?queryText=&pageSize=200&startIndex=0&browseQuery=true> [Pristupljeno: 27. lipnja 2025.]
- [20] Ezzeddini L, Ktari J, Frikha T, Alsharabi N, Alayba A, J Alzahrani A, Jadi A, Alkholidi A, Hamam H. Analysis of the performance of Faster R-CNN and YOLOv8 in detecting fishing vessels and fishes in real time. *PeerJ Computer Science*. 2024;10: 2033. Preuzeto s: <https://doi.org/10.7717/peerj-cs.2033> [Pristupljeno: 16. kolovoza 2025.]
- [21] Lovreković L. *Primjena evaluacijskih tehnika na primjeru konvolucijske neuronske mreže*. Završni rad. Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje; 2021. Preuzeto s: <https://urn.nsk.hr/urn:nbn:hr:235:669818> [Pristupljeno: 11. kolovoza 2025.]
- [22] Ajayi OG, Ashi J, Guda B. Performance evaluation of YOLO v5 model for automatic crop and weed classification on UAV images. *Smart Agricultural Technology*. 2023;5: 100231. Preuzeto s: <https://doi.org/10.1016/j.atech.2023.100231>. [Pristupljeno: 10. kolovoza 2025.]
- [23] Hrvatska agencija za civilno zrakoplovstvo. *P R I O P Ć E N J E - Porast broja ugrožavanja putničkih zrakoplova protupravnim korištenjem dronova u RH*. Preuzeto s: <https://www.ccaa.hr/p-r-i-o-p-c-e-n-j-e---porast-broja-ugrozavanja-putnickih-zrakoplova-protupravnim-koristenjem-dronova-u-rh-24370> [Pristupljeno: 1. kolovoza 2025.]

- [24] Bala A, Muqaibel AH, Iqbal N, Masood M, Oliva D, Abdullahi M. Machine learning for drone detection from images: A review of techniques and challenges. *Neurocomputing*. 2025;635: 129823. Preuzeto s: <https://doi.org/10.1016/j.neucom.2025.129823> [Pristupljeno: 1. kolovoza 2025.]
- [25] Republika Hrvatska. *Zakon o zračnom prometu*. Izdanje: NN 69/2009. Zagreb: Narodne novine; 2009. Preuzeto s: [/eli/sluzbeni/2009/69/1663](https://eli.sluzbeni/2009/69/1663) [Pristupljeno: 18. kolovoza 2025.]
- [26] Ivanković M, Stipičević M, Stipetić S, Vuličević N, Bilić B, Radišić T. Vizualni i termalni skupovi podataka te model za detekciju bespilotnih letjelica na termalnim snimkama. Zenodo; 2025. Preuzeo s: https://zenodo.org/search?q=metadata.creators.person_or_org.name%3A%22Stipetić%20Matko%22&l=list&p=1&s=10&sort=bestmatch

SAŽETAK

Sandra Stipetić, Mila Ivanković, Bruno Bilić, Matko Stipičević

Izrada YOLO modela za detekciju bespilotnih letjelica na termalnim snimkama

U ovome radu opisan je razvoj modela koji s velikom preciznošću detektira bespilotne letjelice na termalnim snimkama. Kako većina današnjih sustava za detekciju bespilotnih letjelica koristi vidljivi dio spektra za obradu snimki, cilj ovog rada bio je osmisliti i razviti model koji bi uspješno detektirao bespilotne letjelice tijekom loših vremenskih uvjeta i noću. Toplinsko zračenje koje bilježi termalna kamera prilikom snimanja omogućilo je da bespilotna letjelica bude vidljiva i u onim trenucima kada je nevidljiva golim okom.

Prilikom razvitka modela jedan od ciljeva bio je i izbjeći ručno označavanje bespilotnih letjelica. Zbog toga je prvotno razvijen model za detekciju bespilotnih letjelica na vizualnim snimkama. Takav model značajno je olakšao kreiranje skupa termalnih snimaka koje su dalje korištene za treniranje novog modela.

Cjelokupni proces detaljno je opisan u radu, od prvog i najvažnijeg koraka koji je bio kreiranje snimki i let bespilotnih letjelica, preko razvitka programskog koda i izrade modela, te do usporedbe različitih rezultata treniranja modela.

Ovaj rad prikazuje uspješnost preciznog detektiranja bespilotnih letjelica na termalnim snimkama pomoću YOLO modela, čime je ostvaren glavni cilj projektnog rada.

Ključne riječi: detekcija bespilotnih letjelica; termalna kamera; YOLO model; *Roboflow*; treniranje modela

SUMMARY

Sandra Stipetić, Mila Ivanković, Bruno Bilić, Matko Stipičević

Creating a YOLO model for UAVs detection in thermal images

This paper describes the development of a model that detects unmanned aerial vehicles (UAVs) on thermal images with high precision. Since most of today's UAVs detection systems use the visible part of the spectrum to process images, the aim of this work was to design and develop a model that would successfully detect UAVs during bad weather conditions as well as at night. The thermal radiation recorded by the thermal imaging camera allowed UAVs to be visible even when it was invisible to the naked eye.

When developing the model, one of the goals was also to avoid manual marking of the UAVs. Therefore, a model was initially developed to detect UAVs on visual images, which greatly facilitated the creation of a set of thermal images that were then used to train the new model.

The entire process is described in detail in this paper, from the first and most important step, which was the creation of the images and the flight of UAVs, to the development of the program code and the creation of the model, and the comparison of different results of the training model.

This work demonstrates the success of the precise detection of UAVs on thermal imagery using the YOLO model, thus achieving the main objective of the project work.

KEY WORDS: UAVs detection; thermal camera; YOLO model, Roboflow, model training

POPIS SLIKA

Slika 1. Hodogram izrade projekta	7
Slika 2. Bepilotna letjelica DJI Mavic 2 Enterprise Dual	8
Slika 3. Bepilotna letjelica Xiaomi FIMI X8 SE	12
Slika 4. Bepilotna letjelica tipa „dodekakopter“	12
Slika 5. Bepilotna letjelica tipa „heksakopter“	13
Slika 6. Bepilotna letjelica tipa „kvadkopter“	13
Slika 7. Bepilotna letjelica DJI Inspire 1 v2	14
Slika 8. Bepilotna letjelica tipa „dodekakopter“ tijekom noćnog snimanja	14
Slika 9. Razvoj YOLO modela tijekom godina, [6]	16
Slika 10. Izgled mape na platformi Roboflow	29
Slika 11. Usporedba vizualne i njoj pripadajuće termalne snimke	30
Slika 12. Sučelje u Roboflow-u za označavanje objekata	34
Slika 13. Primjer augmentacije na snimkama	38
Slika 14. Primjer netočne (dvostruke) detekcije iste bespilotne letjelice	50
Slika 15. Matrica konfuzije za dobiveni model odmah nakon treniranja	51
Slika 16. Matrica konfuzije za dobiveni model nakon nezavisne validacije	52
Slika 17. Detekcija objekata korištenjem početnog YOLO11x.pt modela	54
Slika 18. Primjer točne detekcije bespilotne letjelice (1/4)	55
Slika 19. Primjer točne detekcije bespilotne letjelice (2/4)	55
Slika 20. Primjer točne detekcije bespilotne letjelice (3/4)	56
Slika 21. Primjer točne detekcije bespilotne letjelice (4/4)	56

POPIS GRAFOVA

Graf 1. Rezultati funkcija gubitka (train) prvog treniranja na vizualnim snimkama ...	19
Graf 2. Rezultati funkcija gubitka (val) prvog treniranja na vizualnim snimkama	20
Graf 3. Rezultati funkcija metrika prvog treniranja na vizualnim snimkama	20
Graf 4. Rezultati funkcija gubitka (train) drugog treniranja na vizualnim snimkama .	25
Graf 5. Rezultati funkcija gubitka (val) drugog treniranja na vizualnim snimkama....	25
Graf 6. Rezultati funkcija metrika drugog treniranja na vizualnim snimkama	26
Graf 7. Rezultati funkcija gubitka (train) prvog treniranje na termalnim snimkama...	36
Graf 8. Rezultati funkcija gubitka (val) prvog treniranja na termalnim snimkama	36
Graf 9. Rezultati funkcija metrika prvog treniranja na termalnim snimkama	37
Graf 10. Rezultati funkcija gubitka (train) drugog treniranje na termalnim snimkama	39
Graf 11. Rezultati funkcija gubitka (val) drugog treniranje na termalnim snimkama .	39
Graf 12. Rezultati funkcija metrika drugog treniranja na termalnim snimkama.....	40
Graf 13. Rezultati funkcija gubitka (train) trećeg treniranje na termalnim snimkama	42
Graf 14. Rezultati funkcija gubitka (val) trećeg treniranje na termalnim snimkama ..	42
Graf 15. Rezultati funkcija metrika trećeg treniranja na termalnim snimkama	43
Graf 16. Rezultati funkcija gubitka (train) četvrtog treniranje na termalnim snimkama	44
Graf 17. Rezultati funkcija gubitka (val) četvrtog treniranje na termalnim snimkama	45
Graf 18. Rezultati funkcija metrika četvrtog treniranja na termalnim snimkama	45
Graf 19. Ovisnost F1 o pouzdanosti za dobiveni model odmah nakon treniranja....	49
Graf 20. Ovisnost F1 o pouzdanosti za dobiveni model na nezavisnom validacijskom setu.....	49

POPIS TABLICA

Tablica 1. Uvjeti tijekom snimanja.....	11
Tablica 2. Vrijednosti funkcija gubitaka na setu za treniranje i metrike na kraju pojedinog treniranja (zeleno su osjenčane vrijednosti najboljih performansi modela)	46
Tablica 3. Vrijednosti funkcija gubitaka na validacijskom setu (najniža vrijednost i vrijednost na kraju treniranja – 100. epoha; zeleno su osjenčane vrijednosti najboljih performansi modela).....	47
Tablica 4. Usporedba konačnih vrijednosti funkcija metrike nakon treniranja i nakon nezavisne validacije.....	48

POPIS KODOVA

Kod 1. Pokretanje prvog treniranja na vizualnim snimkama.....	18
Kod 2. Nastavak prekinutog treniranja	24
Kod 3. Preračunavanje koordinata s vizualnih snimki u one na termalnim	32
Kod 4. Pokretanje treniranja YOLO modela na termalnim snimkama	35
Kod 5. Treće treniranje na termalnim snimkama.....	41

PRILOG 1. *PYTHON* KOD TRANSFORMACIJE KOORDINATA

```
import os
import cv2

dir_txt_vis = "D:/ZIN projekt 2025/vizualni dataset/W2/labels"

for dat in os.scandir(dir_txt_vis):
    file = open(dat.path, "r")
    a = file.read()
    file.close()

    v_x = float(a.split()[1])
    v_y = float(a.split()[2])
    v_w = float(a.split()[3])
    v_h = float(a.split()[4])

    #računanje termalnih koordinata
    t_x = (v_x * 640 - 120) / 432
    t_y = (v_y * 480 - 76) / 342
    t_w = (v_w * 640) / 432
    t_h = (v_h * 480) / 342

    #kreiranje imena za termalni label file
    name = os.path.basename(dat.path).split("/")[-1]
    broj = int(name[4:8])
    if broj == 999:
        broj = 1
    else:
        broj += 1
    if broj < 10:
        name_T = name.replace(name[4:8], "000"+str(broj)).replace(
            (name[9], "T"))
    elif broj < 100:
        name_T = name.replace(name[4:8], "00"+str(broj)).replace(
            (name[9], "T"))
```

```

elif broj < 1000:
    name_T = name.replace(name[4:8], "0"+str(broj)).replace
(name[9], "T")
    name_T = name_T[:10]+".txt"

    #kreira termalni label file
    location = "D:/ZIN projekt 2025/ORG slike/T/T2/labels"
    nameoffile = os.path.join(location, name_T)
    file = open(nameoffile, "w")
    file.write("0 "+ str(t_x) + " " + str(t_y) + " " + str(t_w) + "
" + str(t_h))
    file.close()

    #crtanje bounding boxa na termalnoj snimci
    name_T = name_T[:10]+".JPG"
    img = cv2.imread("D:/ZIN projekt 2025/ORG
slike/T/T2/images/"+name_T)

    x1 = int(t_x * 640 - ((t_w * 640) / 2))
    y1 = int(t_y * 512 - ((t_h * 512) / 2))
    x2 = int(t_x * 640 + ((t_w * 640) / 2))
    y2 = int(t_y * 512 + ((t_h * 512) / 2))

    cv2.rectangle(img, (x1, y1), (x2, y2), (0,255,0), 2)

    font_scale = 0.7
    font_thickness = 1
    font = cv2.FONT_HERSHEY_SIMPLEX
    img = cv2.putText(img, "Drone", (int(int(t_x*640)-
int(t_w*640)/2), int(int(t_y*512)-int(t_h*512)/2)), font,
font_scale, (0,255,0), font_thickness, cv2.LINE_AA)
    cv2.imshow(name_T, img)
    cv2.waitKey(0) #Wait for a key press
    cv2.destroyAllWindows()

```

ŽIVOTOPISI AUTORA

Sandra Stipetić rođena je 27. rujna 1999. u Zagrebu, Hrvatska. Srednjoškolsko obrazovanje završila je 2018. u Zrakoplovnoj tehničkoj školi Rudolfa Perešina u Velikoj Gorici, smjer Zrakoplovni prometnik. Godine 2022. stekla je zvanje stručne prvostupnice – inženjerke zrakoplovnog inženjerstva s pohvalom dekana na Veleučilištu Velika Gorica, na studiju Održavanja zrakoplova. Trenutno je studentica diplomskog studija Aeronautike na Fakultetu prometnih znanosti Sveučilišta u Zagrebu.

Mila Ivanković rođena je 9. srpnja 1998. u Zagrebu, Hrvatska. Srednjoškolsko obrazovanje općeg smjera u V. gimnaziji u Zagrebu završila je 2017. Zvanje sveučilišne prvostupnice inženjerke aeronautike stekla je 2024. na Sveučilištu u Zagrebu, Fakultetu prometnih znanosti, studiju Aeronautike, smjer Pilot, te usmjerenje Civilni pilot. Trenutno je studentica diplomskog studija Aeronautike na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu.

Bruno Bilić rođen je 16. veljače 1999. u Zagrebu, Hrvatska. Srednjoškolsko obrazovanje općeg smjera u VI. gimnaziji u Zagrebu završio je 2017. Zvanje sveučilišnog prvostupnika inženjera aeronautike stekao je 2024. na Sveučilištu u Zagrebu, Fakultetu prometnih znanosti, studiju Aeronautika, smjer Upravljanje zračnim prometom, te usmjerenje Kontrola zračnog prometa. Trenutno je student diplomskog studija Aeronautike na Fakultetu prometnih znanosti, Sveučilišta u Zagrebu.

Matko Stipičević rođen je 21. lipnja 2002. u Zagrebu, Hrvatska. Srednjoškolsko obrazovanje informatičkog smjera u XV. gimnaziji u Zagrebu završio je 2021. Zvanje sveučilišnog prvostupnika inženjera aeronautike s najvećom pohvalom stekao je 2024. na Sveučilištu u Zagrebu, Fakultetu prometnih znanosti, studiju Aeronautika, smjeru Pilot i usmjerenju Civilni pilot. Dobitnik je triju Dekanovih nagrada za najbolji uspjeh na prijediplomskom studiju. Od 25. ožujka 2025. posjeduje dozvolu profesionalnog pilota CPL(A). Trenutno je na diplomskom studiju Aeronautika.