

# Praćenje leta maslininog moljca razvojem i korištenjem modela umjetnih neuronskih mreža

---

**Zdrilić, Andelo**

**Master's thesis / Diplomski rad**

**2023**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/um:nbn:hr:204:866325>

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

*Download date / Datum preuzimanja:* **2024-12-27**



*Repository / Repozitorij:*

[Repository Faculty of Agriculture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU

**AGRONOMSKI FAKULTET**

**Praćenje leta maslininog moljca razvojem i  
korištenjem modela umjetnih neuronskih mreža**

DIPLOMSKI RAD

Anđelo Zdrilić

Zagreb, rujan, 2023.

SVEUČILIŠTE U ZAGREBU

**AGRONOMSKI FAKULTET**

Diplomski studij:

Mediteranska poljoprivreda

**Praćenje leta maslininog moljca razvojem i  
korištenjem modela umjetnih neuronskih mreža**

**DIPLOMSKI RAD**

Anđelo Zdrilić

Mentor:

Izv. prof. dr. sc. Tomislav Kos

Komentor:

Izv. prof. dr. sc. Ivana Pajač Živković

Zagreb, rujan, 2023.

SVEUČILIŠTE U ZAGREBU  
AGRONOMSKI FAKULTET

IZJAVA STUDENTA  
O AKADEMSKOJ ČESTITOSTI

Ja, **Anđelo Zdrilić**, JMBAG 0023121567, rođen/a 29.04.1997. u Zadru, izjavljujem da sam samostalno izradio diplomski rad pod naslovom:

**Praćenje leta maslininog moljca razvojem i korištenjem modela umjetnih neuronskih mreža**

Svojim potpisom jamčim:

- da sam jedini autor ovoga diplomskog rada;
- da su svi korišteni izvori literature, kako objavljeni tako i neobjavljeni, adekvatno citirani ili parafrazirani, te popisani u literaturi na kraju rada;
- da ovaj diplomski rad ne sadrži dijelove radova predanih na Agronomskom fakultetu ili drugim ustanovama visokog obrazovanja radi završetka sveučilišnog ili stručnog studija;
- da je elektronička verzija ovoga diplomskog rada identična tiskanoj koju je odobrio mentor;
- da sam upoznat s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

U Zagrebu, dana \_\_\_\_\_

*Potpis studenta*

SVEUČILIŠTE U ZAGREBU

**AGRONOMSKI FAKULTET**

**IZVJEŠĆE**

**O OCJENI I OBRANI DIPLOMSKOG RADA**

Diplomski rad studenta **Anđela Zdrilića**, JMBAG 0023121567, naslova

**PRAĆENJE LETA MASLININOG MOLJCA RAZVOJEM I KORIŠTENJEM MODELA UMJETNIH  
NEURONSKIH MREŽA**

obranjen je i ocijenjen ocjenom \_\_\_\_\_, dana \_\_\_\_\_.

Povjerenstvo: \_\_\_\_\_ potpisi:

1. Izv. prof. dr. sc. Tomislav Kos mentor \_\_\_\_\_
2. Izv. prof. dr. sc. Ivana Pajač Živković komentor \_\_\_\_\_
3. Izv. prof. dr. sc. Darija Lemić član \_\_\_\_\_
4. Prof. dr. sc. Martina Skendrović Babojelić član \_\_\_\_\_

## **Zahvala**

Neizmjerno se zahvaljujem izv. prof. dr. sc. Tomislavu Kosu što mi je pružio mogućnost provedbe istraživanja na temelju kojeg je nastao moj diplomski rad. Zahvaljujem se na mentorstvu, vodstvu i nesebičnom dijeljenju iskustva i znanja, kako tijekom pisanja ovog rada, tako i kroz sve godine mog fakultetskog obrazovanja.

Također se zahvaljujem i komentorici izv. prof. dr. sc. Ivani Pajač Živković na mentorstvu koje je uvelike doprinijelo pisanju ovog rada.

Zahvaljujem se i izv. prof. dr. sc. Dariji Lemić te prof. dr. sc. Martini Skendrović Babojelić na savjetima i kritikama koje su doprinijele stvaranju ovog rada.

Posebne zahvale svojim kolegama prve generacije Mediteranske poljoprivrede koji su mi nesebično pomagali i podupirali me tijekom školovanja. Moram izdvojiti kolegicu Anteu Škarić koja mi je bila kolegica, prijateljica i utjeha u svim trenutcima, od prvog dana preddiplomskog do zadnjeg dana diplomskog studija.

Hvala svim prijateljima i članovima moje obitelji na strpljenju, potpori i brizi koju su iskazali mnogo puta na mnogobrojne načine.

## **Sadržaj**

1.	Uvod .....	1
1.1.	Cilj istraživanja .....	2
2.	Pregled literature .....	3
2.1.	Maslinin moljac ( <i>Prays oleae</i> Bernard, 1788).....	3
2.2.	Biologija, ekologija i štete .....	4
2.3.	Praćenje i zaštita .....	6
2.4.	Tehnologije korištene u sustavima za automatsko praćenje štetnika .....	6
2.4.1.	Strojno učenje .....	7
2.4.2.	Umjetne neuronske mreže .....	8
2.4.3.	Internet stvari.....	11
2.4.4.	Pohrana podataka na „Cloud“ .....	11
2.5.	Dijelovi sustava za automatsko praćenje štetnika .....	11
3.	Materijali i metode.....	14
3.1.	Prikupljanje podataka .....	14
3.2.	Priprema podataka .....	15
3.3.	Razvoj umjetne neuronske mreže .....	17
4.	Rezultati i rasprava .....	19
5.	Zaključak.....	23
6.	Popis literature .....	24
	Životopis .....	28

## **Sažetak**

Diplomskog rada studenta **Andjela Zdrilića**, naslova

### **Praćenje leta maslininog moljca razvojem i korištenjem modela umjetnih neuronskih mreža**

Maslinin moljac (*Prays oleae* Bernard, 1788) jedan je od najznačajnijih štetnika masline. U maslinicima radi štete velikih gospodarskih razmjera, najčešće u obliku opadanja plodova, slabijem urodu i sporijem rastu stabla. Kako bi se njegova prisutnost na terenu ranije uočila, predložen je razvoj modela za automatsku detekciju temeljen na prepoznavanju sadržaja slika pomoću umjetnih neuronskih mreža. Postavljanjem lovki s feromonima, prikupljanjem i fotografiranjem uzoraka, na lovnama ulovljenih, odraslih oblika *P. oleae* na ljepljivim pločama, anotiranjem fotografija i učenjem neuronske mreže, razvijen je model za automatsko praćenje ovog štetnika. Osim vrste *P. oleae*, model je naučen prepoznavati ostale kukce kao i ostale elemente na slikama. Preciznost prepoznavanja odraslih oblika moljca iznosila je 59 % u odnosu na vizualni pregled, a veća je od preciznosti prepoznavanja ostalih štetnika i ostalih elemenata na fotografijama ljepljivih ploča.

**Ključne riječi:** automatsko praćenje štetnika, *Olea europaea* L., *Prays oleae* Bernard, 1788, umjetne neuronske mreže

## **Summary**

Of the master's thesis – student **Andelo Zdrilić**, entitled

### **MONITORING OF THE FLIGHT OF OLIVE KERNEL BORER BY DEVELOPING AND USING MODEL BASED ON ARTIFICIAL NEURAL NETWORKS**

Olive kernel borer (*Prays oleae* Bernard, 1788) is one of the most significant pests of olive tree. In olive groves, it can cause damage of large economic proportions, commonly in form of fruit drop, weaker yield, or stagnant tree growth. To detect its presence in the field as soon as possible, an automatic model based on the image recognition of image content using artificial neural networks is used. By setting up pheromone-based traps, collecting and photographing samples of adult *P. oleae*, annotating photographs and teaching a neural network to use them, an automatic model is developed for tracking olive kernel borer individuals. Besides the species *P. oleae*, the model was taught to recognize other pests as well as other elements of proposed images. The accuracy of recognition of the adult moths was 59 % compared to visual inspection of proposed photographs and was higher than the accuracy of recognition of other pests and other elements on photographs of adhesive panels.

**Keywords:** artificial neural networks, automatic pest monitoring, *Olea europaea* L., *Prays oleae* Bernard, 1788

## 1. Uvod

Maslinin moljac (*Prays oleae* Bernard, 1788) gospodarski je značajan štetnik masline iz reda Lepidoptera. Razvijajući tri generacije godišnje, najveću štetu radi generacija koja napada i uništava plodove, te izaziva njihovo opadanje (Pascual i sur., 2022). Upravo zbog činjenice da maslinin moljac razvija tri generacije, od kojih svaka napada različiti organ masline – cvijet, plod i list, dolazi do pada u kvaliteti plodova i ulja. Osim toga, *P. oleae* može utjecati i na manji urod i na smanjen rast stabala masline (Nobre i sur., 2018).

Praćenje ovog štetnika je od velike važnosti jer potencijalno može uništiti do 90 % plodova u nasadu maslina, što rezultira velikim ekonomskim gubicima za uzgajivače (Maceljski, 2002). Praćenje moljca još uvijek se provodi feromonskim lovckama (Bjeliš, 2009). Problem kod ovakvog načina praćenja je u tome što je *P. oleae* termofilna vrsta i broj leptira varira ovisno o promjenama u temperaturi (Kumral i sur., 2005). Za točan podatak o brojnosti štetnika u masliniku bilo bi potrebno svakodnevno pregledavati i mijenjati ljepljive podloge u feromonskim lovckama i brojati ih, što oduzima vrijeme i povećava troškove (Kumral i sur., 2005). Kako bi se prepoznavanje i brojanje štetnika ubrzalo uz smanjenu potrebu za ljudskim radom, predlaže se razvoj automatskog sustava za praćenje odraslih oblika vrste *P. oleae*.

Važna značajka sustava za automatsko praćenje štetnika je smanjenje potrebe za ljudskim radom. Korištenjem automatskih sustava, dobiva se informacija o situaciji na terenu, obavlja se monitoring štetnika, dobiveni podaci se klasificiraju i koristite se za predviđanje pojave štetnika i trenutka napada. Ovakvi sustavi pripadaju u domenu precizne poljoprivrede, kojoj je cilj smanjiti uporabu pesticida i utrošenog vremena za odlaske na teren, te precizno, brzo i pravovremeno dati preporuke za smanjenje štete (Kos i sur., 2021). Osim u konvencionalnoj poljoprivredi, implementacija takvih sustava je korisna u situacijama kad su mjere zaštite nedostatne, kao što je slučaj u ekološkoj proizvodnji (Preti i sur., 2021).

Maslina (*Olea europaea* Linnaeus, 1753) je vazdazelena mediteranska vrsta koju ljudi uzgajaju preko pet tisuća godina (Fraga i sur., 2021). Na mediteranskim područjima ima velik tradicionalan, gospodarski i kulturni utjecaj koji je itekako prisutan u svakodnevnim životima stanovnika tih područja. U Dalmaciji će se rijetko naći okućnica bez masline ili stol bez maslinovog ulja na njemu. Prema EUROSTAT-ovim podacima, 2022. godine proizvedeno je preko 40000 tona maslina za preradu u ulje (EUROSTAT, 2023).

„*Image recognition*“ (IR) ili prepoznavanje slika dio je strojnog učenja odgovoran za prepoznavanje elemenata na danim slikama. Sam proces provodi se pomoću umjetne inteligencije, a u kontekstu agronomije može se koristiti za označavanje, prepoznavanje i klasifikaciju biljnih štetnika i bolesti (Yuan i sur., 2022).

U radu je obrađeno kreiranje i određivanje preciznosti automatskog sustava za praćenje *P. oleae* u svrhu praćenja populacije odraslih leptira s ciljem pravovremene zaštite masline.

### **1.1. Cilj istraživanja**

Cilj istraživanja je razviti model za automatsko vizualno praćenje maslininog moljca temeljen na umjetnoj neuronskoj mreži.

## 2. Pregled literature

### 2.1. Maslinin moljac (*Prays oleae* Bernard, 1788)

Maslinin moljac štetnik je iz reda Lepidoptera koji radi štete na svim područjima uzgoja masline, tj. na Mediteranu i Bliskom Istoku. Jedan je od najznačajnijih štetnika masline u našem podneblju, pogotovo na područjima Zadarske i Šibenske županije, te na otocima, gdje radi veće štete od maslinine muhe (Bjeliš, 2009). Vrsta *P. oleae* napravi štete na prosječno 20 % plodova u maslinicima, iako se taj postotak može značajno povisiti, do 50 pa čak i 100 % ukoliko se ne poduzmu mjere zaštite (Maceljski, 2002). Osim masline, napada zeleniku (*Phylirea latifolia* L., 1758.), jasmin (*Jasminum officinale* L., 1758.) i kalinu (*Ligustrum japonicum* Thunb., 1770.) (Maceljski, 2002.). Postoje kultivari masline više otporni na napad ovog štetnika, a to su kultivari sitnjeg ploda. Od autohtonih, otporna je sorta 'Lastovka', a od introduciranih najotpornija je sorta 'Pendolino' (Maceljski, 2002).

Odrasli leptir vrste *P. oleae* sive je boje s rasponom krila od 11 do 14 mm (slika 2.1.1.). Boja ličinki razlikuje se ovisno o ishrani pa su tako gusjenice cvjetne generacije žutosmeđe, a gusjenice kasnijih generacija zelene boje (Maceljski, 2002).



Slika 2.1.1. Prikaz odraslog oblika vrste *P. oleae*.

Izvor: <https://biochemtech.eu/products/olive-kernel-borer-prays-oleae>

## 2.2. Biologija, ekologija i štete

Životni ciklus *P. oleae* usko je vezan uz fenofaze razvoja masline, pa razvija tri generacije godišnje (Bjeliš, 2009).

Minimalna temperatura za aktivnost odraslih oblika ovog štetnika je 10 °C, a njihovo ugibanje počinje već na 7 °C. Također, temperature iznad 30 °C imaju isti negativan utjecaj na odrasle leptire. Temperature ispod 0 °C izazivaju stradavanje jaja (Civantos-Ruiz i sur., 2022).

Prva generacija naziva se antofagna jer ženke, u razdoblju od travanja do svibanja odlažu jaja, uglavnom pojedinačno, na čašku, rijede na vjenčić cvijeta masline. Iz jaja se razvijaju gusjenice koje se hrane cvjetnim pupovima, a jedna gusjenica može uništiti do 40 cvjetnih pupova (Bjeliš, 2009). Razvoj gusjenice traje prosječno 60 do 61 dan (Shehata i sur., 2003). Nakon što u potpunosti naprave štetu u cvjetnom pupu, gusjenice migriraju do sljedećeg cvijeta, zapredajući prethodnog u svilenkaste niti. Kukuljenje se odvija u takvom cvjetnom zapretku ili, ukoliko padne na tlo, na suhom lišću i biljnim ostacima (Bjeliš, 2009). Izljetanje odraslih oblika odvija se danju, a ovipozicija noću (Shehata i sur., 2003).

Druga generacija naziva se karpofagna jer napada plod, javlja se u lipnju i tada nastaju najveće štete u maslinicima. Tijekom fenofaza 71 do 75 prema BBCH (Biologische Bundesanstalt Bundessortenamt Chemische Industrie) skali, odnosno dok je plod veličine „glave šibice“, ženke odlažu jaja na spoju peteljke i tek razvijenog ploda (Maceljski, 2002). Bjeliš (2009) navodi kako odrasle jedinke ne odlažu jaja na plodove manje od 4 mm. U slučaju nedostatka plodova, ženke ove generacije odlažu jaja i na listove. Na slici 2.2.1. prikazano je kako se zelenkaste gusjenice ubušuju u plod masline i hrane endospermom i sjemenkom, što onemogućuje daljnji razvoj ploda (Maceljski, 2002).



Slika 2.2.1. Štete na plodu masline nastale ishranom gusjenica druge generacije vrste *P. oleae*.

Izvor: <https://biochemtech.eu/products/olive-kernel-borer-prays-oleae>

Nakon ishrane, gusjenica napušta plod bušeći kanal blizu peteljke, što izaziva opadanje ploda (Bjeliš, 2009). Shehata i sur. (2003) navode kako ženke odlažu više jaja u drugoj generaciji i kako razvoj gusjenica ove generacije traje prosječno 15 dana kraće od onih iz prve generacije. Štetu rade i odrasle gusjenice ove generacije u razdoblju od kolovoz do rujna, kad izlaze iz plodova i pletu svilenkaste niti oko cvjetova i na lišću (slika 2.2.2.) što rezultira opadanjem tih biljnih organa (Andreadis i sur., 2011). Tako gusjenice dospiju na tlo gdje se kukulje među lišćem i grančicama (Shehata i sur., 2003).



Slika 2.2.2. Prikaz zapredene gusjenice vrste *P. oleae*.

Izvor: <https://www.flickr.com/photos/mrshentz/7118016241/in/photostream/>

Treća generacija je filofagna, javlja se u rujnu i ne izaziva velike ekonomске štete. Odrasli oblici odlažu jaja na listu i njihove gusjenice hrane se lisnim parenhimom. Na slici 2.2.3. prikazane su štete koje rade u obliku nepravilnih bušotina dugih 2 do 5 cm u listovima, takozvane mine. Tijekom siječnja i veljače, gusjenice se ponovo ubušuju u isti list ili prelaze na novi, gdje se hrane do ožujka, kad ciklus od tri generacije započinje ponovno (Bjeliš, 2009). Prema Andreadis i sur. (2011), razvoj treće generacije traje najduže, pa se tako mogu pronaći odrasli oblici ove generacije od rujna pa sve do kraja studenog.



Slika 2.2.3. Prikaz mina na listu masline.

Izvor: <https://www.flickr.com/photos/mrshentz/7079067117/in/photostream/>

### **2.3. Praćenje i zaštita**

Praćenje maslininog moljca provodi se feromonskim lovckama čije su osnovne komponente sintetizirani seksualni miris ženki i ljepljivi podložak na kojem se ulove mužjaci privučeni feromonom. Brojanjem odraslih oblika određuju se rokovi i prag odluke suzbijanja štetnika (Kumral i sur., 2005).

Lisnu generaciju nije potrebno tretirati jer postoji mogućnost reinfekcije u cvjetnoj generaciji. Tretiranje ove generacije preporuča se u mladim maslinicima kada je napadnuto više od 10 % vršnih i/ili 25 % svih vršnih i postranih pupova (Bjeliš, 2009).

Rokovi suzbijanja gusjenica antofagne generacije ovise, osim o količini ulovljenih jedinki, i o postotku otvorenih cvjetova na maslini kao i o pripravku koji se koristi. Pri korištenju pripravaka na bazi spinosada ili piretrina, potrebno je tretiranje obavljati deset dana prije otvaranja cvijeta jer tada odrasli oblici maslininog moljca polažu jaja (Bjeliš, 2009). Kod tretiranja sredstvima na bazi azadirahitina ili na bazi bakterije *Bacillus thuringiensis*, zaštita se obavlja u fenofazi kad je otvoreno otprilike 5 % cvjetova. Uz to, tretiranje sredstvima za zaštitu bilja potrebno je obaviti samo kad je ulov u lovckama veći od pet leptira u lovci dnevno. Tretiranja se nikada ne obavljaju kad je otvoreno više od 20 % fertilnih cvjetova niti kad je manje od pet živih gusjenica na jednoj mladici (Bjeliš, 2009).

Rok suzbijanja maslininog moljca u karpofagnoj generaciji obavlja se kad više od 40 % plodova u sebi ima gusjenicu moljca. Preporuča se tretiranje sredstvima za zaštitu masline, no moguće ih je i mehanički spriječiti metodom masovnog lova. Metoda djeluje tako da se postavlja jedna lovka s feromonom po stablu ili se postavljaju žute ploče uz dodatak feromonske ampule kako bi se ulovio što veći broj odraslih oblika štetnika (Bjeliš, 2009).

### **2.4. Tehnologije korištene u sustavima za automatsko praćenje štetnika**

Konstantnim klimatskim i antropogenim promjenama na uzgojnim prostorima, dosadašnje metode praćenja štetnika i određivanja rokova suzbijanja postaju nepraktične. Iz tog razloga, diljem svijeta razvijaju se sustavi za automatsko praćenje pojave štetnika koje prepoznaju i klasificiraju štetnika (Cardim Ferreira Lima i sur., 2020). Uz to, smanjuju potrebu za odlascima na teren, smanjujući pri tome transport i emisiju štetnih plinova (Čirjak i sur., 2022). Ovakvi sustavi samostalno pregledavaju biljke, pronalaze štetnike, s naglaskom na što raniju detekciju,

broje ih, a agronomi te informacije koriste za određivanje praga odluke tretiranja na svojim uzgojnim površinama (Kasinathan i Uyyala, 2020). Cilj spajanja automatskih sustava s agronomijom je razviti uzgojne sustave koji su profitabilniji, održivi, ekološki prihvativiji, pri čemu rastu kvaliteta i kvantiteta proizvedene hrane, a smanjuje se šteta na plodovima. Povrh toga, ove tehnologije imaju sposobnost brze prilagodbe na klimatske promjene, što je danas, u biljnoj proizvodnji, potrebno više nego ikad (Cardim Ferreira Lima i sur., 2020).

Moderna integrirana zaštita bilja još se uvijek temelji na intenzivnom prikupljanju i obradi podataka, za što je potrebno školovati osoblje kroz niz godina. Uz to, mnogobrojni odlasci na teren, mijenjanje ploča za praćenje štetnika, pojedinačan pregled biljaka, i slični poslovi, zahtijevaju gotovo konstantnu ljudsku prisutnost, a to iziskuje velike količine rada kroz duže vremensko razdoblje (Čirjak i sur., 2022).

Xia i sur. (2018) opisuju učinkovitost automatskih sustava za prepoznavanje štetnika u rješavanju sljedećih problema:

- 1) Uspješno prepoznavanje promatranih štetnika na kompleksnoj pozadini, bilo to na listu, cvijetu, grani ili nekom drugom biljnom organu;
- 2) Precizno razlikovanje promatranog štetnika od ostalih štetnika;
- 3) Razlikovanje različitih fenotipova iste vrste štetnika.

Sustavi sposobni za rješavanje ovih problema temeljeni su na kombiniranom znanju iz agronomije, strojnog učenja, korištenja Interneta stvari (eng. „*Internet of Things*“, „*IoT*“), senzorike i srodnih znanosti (Basori i sur., 2020).

#### **2.4.1. Strojno učenje**

Strojno učenje (eng. „*Machine learning*“) (ML) grana je računalnih znanosti, točnije umjetne inteligencije (eng. „*Artificial Intelligence*“) (AI) koja, temeljem niza algoritama, obrađuje informacije na ljudskom mozgu sličan način (IBM, 2023a).

Prepoznavanje uzorka je znanstvena disciplina koja je svrstana u strojno učenje, a cilj joj je klasificirati naučene objekte u kategorije koje nazivamo razredi (eng. „*classes*“). Ovisno o svrsi uporabe, moguće je klasificirati različite objekte, slike, signale i ostalo (Theodoridis i Kountroumbas, 2008). Napretkom računala, prepoznavanje uzorka je značajno napredovalo,

tako da moderna računala mogu paralelno uspoređivati nekoliko značajki. Ova znanost srž je svakog automatskog sustava koji se temelji na donošenju odluka putem AI-a u strojnom učenju. Primjeri upotrebe prepoznavanja uzoraka u svakodnevnici uključuju prepoznavanje slova i znakova, prepoznavanje zvuka i pretvaranje u tekst, dijagnostika potpomognuta umjetnom inteligencijom u medicini, dubinska analiza podataka, prepoznavanje otiska prsta, lica i slično (Theodoridis i Kountroumbas, 2008). Potamitis i sur. (2017) navode primjer korištenja prepoznavanja uzoraka u agronomiji pomoću svjetlosnih lovki. Kad u lovku s dnom prekrivenim infracrvenim diodama uleti kukac, lovka šalje informacije o prekidanju svjetlosnih snopova i na račun tih podataka može s preciznošću odrediti o kojem se štetniku radi. Osim toga, navode prepoznavanje uzorka mahanja krilima, te vibracije koje određeni kukci ispuštaju tijekom hranjenja (Potamitis i sur., 2017).

Strojno učenje može biti u potpunosti, djelomično i nimalo nadgledano od strane čovjeka. Nadgledano učenje je ono učenje u kojem automatski sustav dobije podatke koje je čovjek već kategorizirao u razrede tako da je klasifikacija unutar sustava odraćena na prethodno dobivenom znanju koje se naziva set za učenje (eng. „*training set*“) (Theodoridis i Kountroumbas, 2008). Nenadgledano učenje dobije samo set podataka koje sustav sam mora klasificirati, po sličnostima, u grupe, odnosno klastere. Djelomično nadgledano učenje dobije set podataka za učenje isto kao u potpuno nadgledanom učenju, no novi ulazni podaci nisu kategorizirani, pa ih sustav mora sam grupirati kao u nenadgledanom strojnom učenju (Theodoridis i sur., 2008). Umjetna inteligencija potkategorija je strojnog učenja. Alan Turing, otac modernih računalnih znanosti, još je 1950. godine u svom radu *Computing Machinery and Intelligence* opisao umjetnu inteligenciju kao igru oponašanja kojim računalo uči razmišljati kao čovjek, sa svrhom rješavanja ljudskih problema, na najbrži i najtočniji mogući način. Prema tome, AI je znanost o prenošenju ljudskog znanja na strojeve.

#### **2.4.2. Umjetne neuronske mreže**

Umjetne neuronske mreže (eng. „*Artificial neural networks*“) (ANN) dio su AI-a, a princip rada nastao im je po uzoru na ljudski mozak. Neuronske mreže sastoje se od ulaznih podataka, skrivenog sloja i izlaznih podataka (Wang, 2003).

Ulagani sloj (eng. „*Input layer*“) čine neuroni na kojima se nalaze ulagni podaci. Te podatke mreža može dobiti, primjerice, u obliku slike s terena ili ih čovjek može sam učitati u mrežu (Wang i sur., 2003).

Skriveni sloj (eng. „*Hidden layer*“) sačinjen je od neurona kojima je uloga procesirati dobivene podatke putem niza algoritama. Skriveni sloj može biti jedan ili njih više, ovisno o količini podataka za obradu. Povećanje količine podataka uglavnom znači i veći broj skrivenih slojeva (Wang i sur., 2003).

Vanjski sloj (eng. „*Output layer*“) čine izlazni neuroni koji daju rezultate obrade unesenih podataka (Wang i sur., 2003).

Prije no što je neuronska mreža sposobna samostalno obrađivati ulagne podatke, potrebno ju je izvježbati pomoću seta podataka za učenje. Takav set podataka služi kako bi mreža naučila koje informacije želimo da nam ona izdvaja. Znanje stečeno vježbanjem, neuronska mreža koristi kasnije kako bi samostalno mogla rješavati probleme i izdvajati bitne značajke čak i na nepotpunim ulagnim podacima, primjerice, na oštećenim slikama (Theodoridis i Kountroumbas, 2008).

Osim detekcije štetnika, umjetne neuronske mreže služe za prebrojavanje štetnika, njihovu klasifikaciju, prepoznavanje slika (IR), predviđanje napada i određivanja praga odluke za tretiranje nasada sredstvima za zaštitu bilja. Prema Kos i sur. (2021) neuronske se mreže mogu koristiti za ranu identifikaciju i klasifikaciju biljnih bolesti, kao i rano otkrivanje biljaka u stresu.

Dahikar i Rode (2014) objasnili su kako je svaka neuronska mreža definirana pomoću tri parametra:

- 1) Vezom između različitih slojeva neurona (veza ulagni-skriveni-izlazni sloj)
- 2) Procesom učenja kojim se ažuriraju vrijednosti neurona
- 3) Aktivacijskom funkcijom koja ulagni podatak nekog neurona pretvara u izlazni

Procesi kroz koje IR sustav potpomognut umjetnom neuronskom mrežom prolazi tijekom rješavanja problema su predprocesiranje, filtriranje, segmentacija i izdvajanje bitnih značajki, te klasifikacija (Kos i sur., 2021).

Predprocesiranje je skup operacija koji diktira koji će se dio ulagnih podataka, primjerice slike, obrađivati u neuronskoj mreži. Nepoželjni čimbenici, poput mutnih i izobličenih dijelova slike se uklanjuju pa se tako i smanjuje količina ulagnih podataka i ubrzava

proces njihove obrade (Kos i sur., 2021). Uz predprocesiranje, provodi se paralelno filtracija podataka tako da se podaci, odnosno slike, koji ne sadrže objekt promatranja, automatski uklanjaju kako ne bi zauzimali dodatni prostor. Uz sve to, naprednije neuronske mreže imaju sposobnost izdvajanja značajki (Ahmad Supian i sur., 2019).

Izdvajanje značajki važan je dio u IR i služi kako bi se predmeti istraživanja, primjerice štetnici i ostali predmeti na lovci, odvojili od pozadine na kojoj se nalaze. Također, u ovom procesu često se podaci prevode u drugi oblik koji je neuronskoj mreži lakši za obrađivati, pogotovo ako je taj format pogodan za smanjenje količine podataka i preciznije izdvajanje značajki. Taj proces naziva se segmentacija (Sethupathy i Veni, 2016). Primjerice, Dhingra i sur. (2018) opisali su kako je, za otkrivanje simptoma bolesti na maslini, pogodno prevesti slike iz klasičnog RGB (slika sačinjena od crvenih, zelenih i plavih piksela) formata u CIELab format (trodimenzionalna reprodukcija boja unutar i izvan vidljivog spektra). Na taj način je povećanja preciznost uklanjanja grešaka iz uzorka, što je rezultiralo manjom količinom podataka i preciznijom detekcijom bolesti.

Klasifikacija je najvažniji dio algoritma neuronske mreže i ključni je dio IR. Koristeći se znanjem iz seta za učenje, kao i znanjem iz prethodnog procesiranja podataka, neuronska mreža određuje koji je dio svih ulaznih podataka zapravo koristan i koji daje rezultat koji nama treba. Konkretno, to bi značilo koji dio ploče sadrži štetnika kojeg mi promatramo ili koji postotak listova je zaražen nekom bolesti. Klasifikacija u IR-u ima ulogu detekcije štetnika ili bolesti i njihovo odvajanje od ostalih elemenata na fotografijama feromonskih ili drugih lovki, dijelova biljke i slično (Kos i sur., 2021).

Ponekad je za razvoj sustava za prepoznavanje štetnika potrebno isprobati više vrsta umjetnih neuronskih mreža. Tako su Popescu i sur. (2022) istražili šest različitih umjetnih neuronskih mreža kako bi dobili što bolje rezultate u prepoznavanju smeđe mramoraste stjenice (*Halyomorpha halys* Stål, 1855). Primjerice, EfficientDet-D0 bila je najbrža mreža u obradi podataka, no nije davala najtočnije rezultate. YOLOv5s mreža najbolje je prepoznavala štetnike, no zahtijevala je najduže vremena za obradu. Osim toga, kompleksnost pozadine fotografija na kojoj su se nalazili uzorci *H. halys* je uvelike diktirala uspješnost prepoznavanja štetnika. Fotografije s komplikiranim pozadinama davale bi najveći broj grešaka i nepreciznu klasifikaciju (Popsecu i sur., 2022).

#### **2.4.3. Internet stvari**

Internet stvari (*IoT*) umreženost je svih fizičkih i nefizičkih cijelina koje mogu biti spojene u jedinstveni smisleni sustav. Sama definicija *IoT*-a još nije određena zbog konstantnog uvođenja novih tehnologija u područje automatskih sustava (Camarinha-Matos i sur., 2013). U slučaju automatskih sustava u agronomiji, *IoT* objedinjuje sve senzore, kamere, dronove, meteorološke postaje, neuronske mreže ili neki drugi tip AI koji procesira podatke, računala, fizičke servere i „*Cloud*“ servere i slične tehnologije, kao i sve načine na koje su cijeline povezane, bilo to bežično ili žično (Fresco i Ferarri, 2018). Jedan takav cjeloviti sustav mora biti varijabilan i prilagodljiv novim problemima i, jednom postavljen, mora funkcionirati bez potrebe za konstantnim ljudskim nadgledanjem (Camarinha-Matos i sur., 2013).

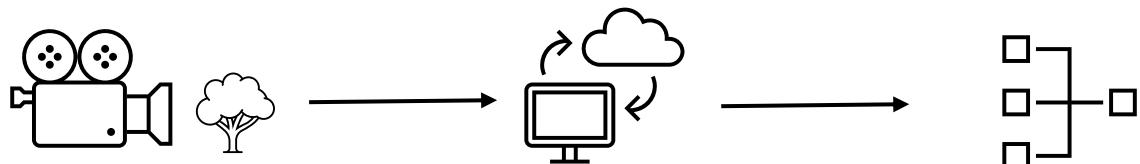
#### **2.4.4. Pohrana podataka na „*Cloud*“**

„*Cloud*“ server ili Oblak je oblik fizičkog ili virtualnog servera koji služi skladištenju, prijenosu, obradi i dijeljenju podataka, a pristupa mu se putem interneta. Svrha ovakve tehnologije je brzo dijeljenje podataka i znanja, jer mu mogu pristupiti, naravno uz zahtjev, pripadnici znanstvene zajednice. Za automatsko praćenje, ovime se značajno ubrzavaju procesi prikupljanja podataka, te je moguće koristiti i podatke koje su drugi korisnici stavili na Oblak (IBM, 2023b). Velike količine podataka pohranjene na „*Cloud*“ serverima poznatiji su pod nazivom „*Big Data*“ (veliki podaci). Kao što sam naziv kaže, prednost automatskih tehnologija nad čovjekom, u ovom smislu, je sposobnost obrade velikih količina informacija o nekoj temi u znatno kraćem vremenu (Osinga i sur., 2022).

### **2.5. Dijelovi sustava za automatsko praćenje štetnika**

Brz razvoj kamera s visokokvalitetnim snimanjem, brzih i malih procesora kao i servera koji mogu pohraniti velike količine podataka doveli su do značajnog napretka u tehnologiji općenito, pa tako i u tehnologijama korištenim u agronomiji. S namjerom da se smanji ljudski rad i poboljša očitavanje podataka sa standardnih lovki za praćenje štetnika – integrirajući takve kamere u različite digitalne sustave, omogućuje se automatsko praćenje štetnika na terenu (Preti i sur., 2021).

Na slici 2.5.1. opisani su dijelovi jednog sustava za automatsko praćenje štetnika. Sustavi se uglavnom sastoje od vanjske kamere, odnosno „snimalice“, koja fotografira pojavu na terenu. Kamere mogu snimati cijela stabla ili samo određene dijelove, cijele nasade ili pak pojedinačne lovke postavljene na terenu (Yalcin, 2015). Prikupljene podatke šalju preko servera do računala za obradu tih podataka. Obrada se obavlja pomoću AI, točnije, putem umjetnih neuronskih mreža (Grünig i sur., 2021).



Slika 2.5.1. Slanje podataka u automatskim sustavima za praćenje štetnika.

Izvor: A. Zdrilić

Čirjak i sur. (2023) opisuju automatski sustav za praćenje minera okruglih mina (*Leucoptera malifoliella* O. Costa, 1836). Na slici 2.5.2. prikazan je sustav razvijen u sklopu provedenog istraživanja. Razvijeni sustav sastoji se od kamere koja snima u crvenom, zelenom i plavom spektru (RGB kamera), koja se nalazi u polikarbonatnoj, bijeloj kutiji, kako bi bila zaštićena od vanjskih vremenskih utjecaja. Uređaj je postavljen na stupove u nasadu jabuka. Razvijeni prototip pametne lovke s obje strane ima lovke kako bi štetnici mogli ući u lovku, privučeni feromonskim mamcem. Osim toga, sustav su činile baterije za napajanje, vanjski solar za solarno napajanje s antenom za 4G i 5G mreže, te temperaturni senzor.

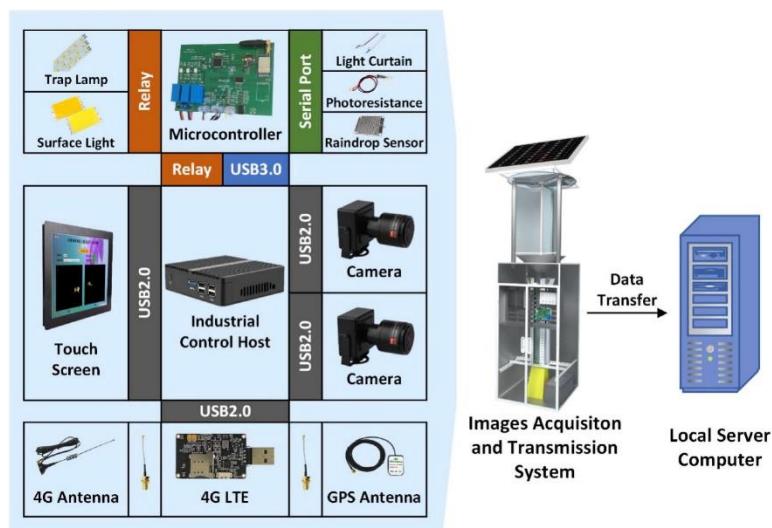


Slika 2.5.2. Razvijeni prototip pametne lovke za praćenje štetnika jabuke.

Izvor. Čirjak i sur. (2023).

Liu i sur. (2022) razvili su automatski sustav za praćenje žute kukuruzne sovice (*Helicoverpa armigera* Hübner, 1808.) i ostalih štetnika na pamuku u Kini (Slika 2.5.3.). Cilj istraživanja bio je napraviti sustav koji može prepoznati te štetnike i povratno slati informacije o brojnosti štetnika na terenu, sve s ciljem preciznijeg predviđanja pojave štetnika.

Na slici 2.5.3. je prikaz korištenog uređaja u istraživanju. Terenski uređaj za slikanje štetnika sastojao se od vanjskog oklopa, sustava za privlačenje štetnika, električnog kontrolnog sustava, kutije za skupljanje ulovljenih jedinki, te uređaja za snimanje i prijenos slika. Osim navedenog, sustav je imao i antenu, uređaj za mjerjenje padalina i termometar. Dvije kamere su se nalazile u uređaju, a sustav je djelovao na način da, kad bi štetnik uletio u lovku, prošao bi ispod svjetlosne trake, koju bi jedna kamera slikala i slala podatke o broju štetnika, poziciji i vremenu slikanja. Budući da promatrane štetnike privlači svjetlost, ispred umjetnog izvora svjetlosti u kutiji stavljeni su prozirni zasloni kako bi štetnik udario u njih i pao u kutiju za skupljanje uzoraka. Druga kamera je slikala i slala podatke iz te kutije (Liu i sur., 2022).



Slika 2.5.3. Sustav za automatsko praćenje štetnika pamuka na polju.

Izvor: Liu i sur. (2022.)

### 3. Materijali i metode

Provedeno istraživanje je podijeljeno u tri faze. Prva faza istraživanja uključuje prikupljanje fotografija na terenu, u svrhu učenja ANN. U drugoj fazi, elementi na fotografijama su označavani i podijeljeni u kategorije. Posljednja faza uključuje izradu modela ANN za prepoznavanje maslininog moljca na temelju prethodno prikupljenih fotografija za učenje i određivanje pouzdanosti modela.

#### 3.1. Prikupljanje podataka

Od svibnja do listopada 2022., te od svibnja do kolovoza 2023. godine prikupljeni su podaci potrebni za istraživanje. Istraživanje je provedeno na obiteljsko-poljoprivrednom gospodarstvu Sikirić u Islamu Grčkom ( $44^{\circ}09'15.4"N$   $15^{\circ}26'29.9"E$ ) u Zadarskoj županiji. U svrhu ulova prve i druge generacije štetnika, 2022. godine postavljen je šest lovki, a 2023. godine tri lovke postavljene su na istom lokalitetu i dvije u maslinik na lokalitetu Poličnik ( $44^{\circ}10'10.0"N$   $15^{\circ}22'51.6"E$ ) u Zadarskoj županiji.

Lovke (slika 3.1.1.) tipa delta (RAG) sastoje se od plastičnog kućišta, ljepljive ploče i feromonskog atraktanta. Na ljepljivim pločama nalazio se po jedan feromonski atraktant u obliku kapsule, koji je privlačio odrasle oblike mužjaka maslininog moljca. Ploče su provjeravane i mijenjane na tjednoj bazi, a feromoni mijenjani jednom u svaka dva tjedna. Ploče su kasnije fotografirane, a slikovni podaci korišteni su za razvoj modela za praćenje štetnika.



Slika 3.1.1 Feromonska lovka za ulov maslininog moljca (a – otvor i ploča, b – ljepljiva ploča, c – feromonski atraktant).

Izvor: A. Zdrilić

Ljepljive ploče fotografirane su pomoću RGB kamere na tjednoj bazi. RGB kamera, prikazana na slici 3.1.2., dolazi s 3.9 mm lećom koja pokriva 75 stupnjeva horizontalnog polja preglednosti (eng. „*Horizontal Field of Vision, HFOV*“). Rezolucije slika su 12.5 megapiksela, odnosno 4056 x 3040 piksela. Fotografije su prikupljene na terenu, kako bi uvjeti fotografiranja bili što sličniji stvarnim uvjetima. Kamera za prikupljanje slikovnih podataka nalazi se u bijeloj, polikarbonatnoj kutiji i spojena je na računalo (eng. „*Single Board Computer, SBC*“). Operativni sustav je Raspberry Pi OS na modelu računala Raspberry Pi 4.



Slika 3.1.2. Prikaz uređaja za uzimanje slikovnih podataka (a – kućište, b – računalo, c – baterija)

Izvor: A. Zdrilić

### 3.2. Priprema podataka

Za razvoj ANN bilo je potrebno slikovne podatke klasificirati. Primjer jedne prikupljene fotografije prikazan je na slici 3.2.1. U svrhu razvoja modela definirane su tri klase:

- 1) Olive\_trap\_moth – odrasli oblik maslininog moljca;
- 2) Trap\_insects\_other – ostali kukci na pločama;
- 3) Trap\_other – ostali objekti na ljepljivim pločama, primjerice lišće, dijelovi grana i cvjetova.

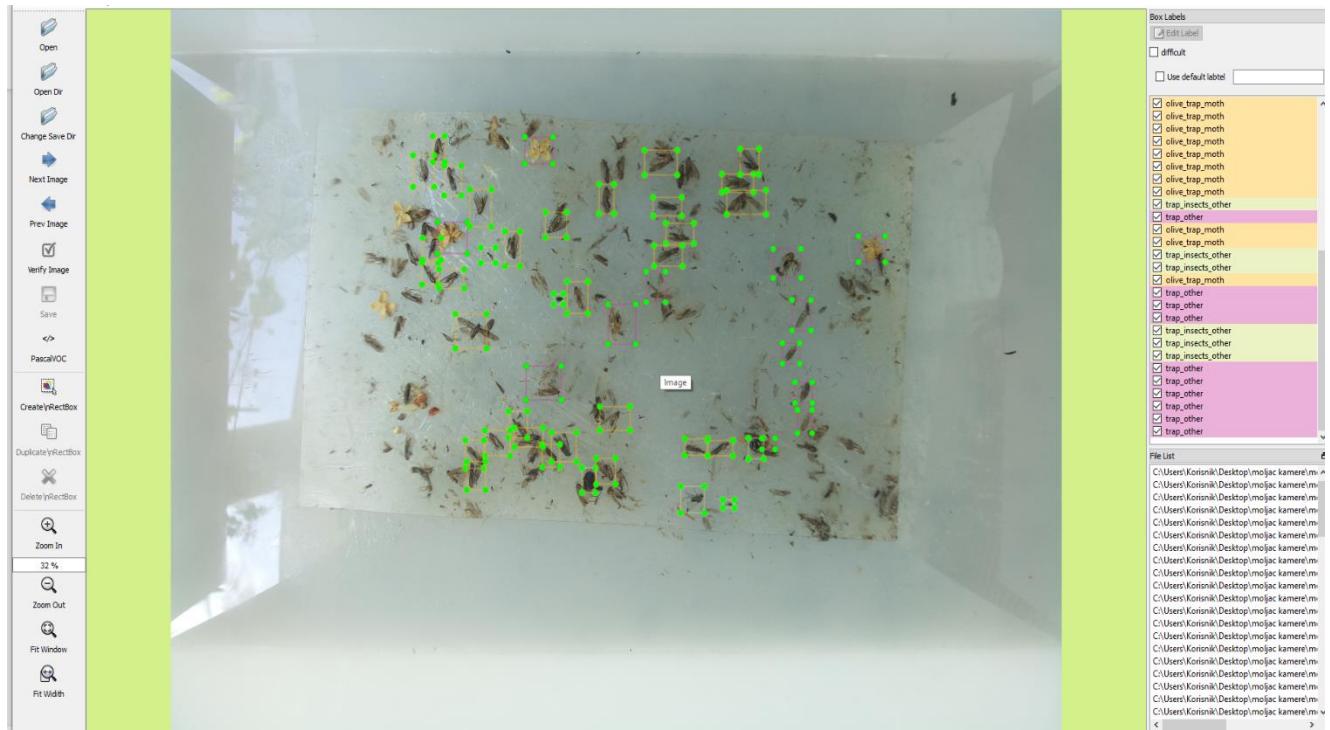


Slika 3.2.1. Neobrađeni vizualni uzorak odraslih oblika vrste *P. oleae* fotografiran uređajem za uzimanje slikovnih uzoraka.

Izvor: A. Zdrilić

Prikupljeni slikovni podaci s ljepljivih ploča, nakon fotografiranja, bili su obrađeni u programu LabelImg, verzija 1.8.1. LabelImg je program koji omogućuje označavanje elemenata na slici i njihovo grupiranje u klase. Taj proces zove se anotiranje. Format u kojem je anotiranje izvedeno je PascalVOC koji spada u XML strukture. Pascal Visual Object Classes (VOC) set je podataka dostupan svima, koji omogućuje korištenje prethodno stvorenih klasa i podataka u svrhu razvoja novih modela temeljenih na strojnom učenju (Section, 2023). U ovom istraživanju korišteni su dijelovi programskog koda iz tog seta za olakšan razvoj sustava za automatsko praćenje maslininog moljca. XML je tip programskog jezika koji služi za pohranu i prijenos podataka, a stvoren je sa svrhom da je jednako razumljiv ljudima i strojevima za čitanje. Zbog svoje strukture u obliku stabla, iznimno je pogodan za pohranjivanje podataka koji imaju više ulaznih jedinica (JavaTPoint, 2023).

Na slikama nisu označavani elementi koji su mutni, na rubu slike ili koji nisu u potpunosti vidljivi. Primjer jedne anotirane fotografije prikazan je na slici 3.2.2. Narančastim kvadratima označeni (anotirani) su odrasli leptiri maslininog moljca pod nazivom Olive\_trap\_moth. Zelenim kvadratima anotirani su ostali kukci koji su se ulovili na ljepljivoj ploči pod nazivom Trap\_insects\_other, a ljubičastim kvadratima anotirani su ostali objekti na slikama pod nazivom Trap\_other.



Slika 3.2.2. Detalj anotiranja u programu LabelImg 1.8.1.

Izvor: A. Zdrilić

### 3.3. Razvoj umjetne neuronske mreže

Prethodno anotirane slike korištene su za razvoj ANN za automatsko praćenje *P. oleae*. Učenje ANN-a počinje s neobrađenim slikama i izdvajanjem bitnih značajki s njih. Za učenje je korišteno 157 fotografija.

Slike su nasumično podijeljene u dvije kategorije: set za učenje i set za potvrdu pouzdanosti. Set za učenje činilo je 80 do 95 % slika, a 5 do 20 % njih korišteno je za potvrdu pouzdanosti modela.

Set za učenje je dio slika koji se koristi za početno učenje modela. Gubitak tijekom učenja (eng. „*Learning loss*“) pojam je koji opisuje koliko dobro ANN obavlja svoj posao, odnosno, kolika je greška modela pri prepoznavanju elemenata sa slika tijekom faze učenja (Baledung, 2023).

Za utvrđivanje potvrde pouzdanosti korišteni su statistički elementi za određivanje preciznosti prepoznavanja objekata - *Average Recall* (AR) i *Average Precision* (AP). Pojam AR opisuje koja je prosječna brojnost moljaca prepoznatih pomoću modela u odnosu na stvarni broj moljaca na slikama. Pojam AP je vrijednost koja određuje koliko je prosječno relevantnih slika u datom setu. Greška pri potvrdi pouzdanosti određuje se zbrajanjem svih grešaka nastalih u prepoznavanju elemenata slika tijekom faze validacije modela (TensorFlow, 2023).

AP50 i AP75 parametri su koji pokazuju prosječnu preciznost za IoU=50 % i IoU=75 %. IoU (eng. „*Intersection over Union*“) vrijednost je koja pokazuje razinu preklapanja dvaju površina, a kreće se između 0 i 1, odnosno između 0 i 100 % (Stanford, 2023). U slučaju detekcije štetnika, to je razina kojom se preklapaju stvarna površina štetnika s predviđenom površinom koju prepoznae ANN (Popescu i sur., 2022). AP50 stoga znači vrijednost prosječne preciznosti kad je preklapanje 50 % između stvarne i, od strane ANN, prepoznate površine koju zauzima štetnik (Popescu i sur., 2022).

Kad se model jednom stvori, potrebno ga je konstantno unaprjeđivati. Računala korištena u razvoju modela hardverski su posebno podešena kako bi mogla podnijeti veliku količinu podataka i procesirati stvaranje samog modela. Zasebni virtualni server postavljen je za pohranu podataka.

Za proizvodnju modela, korištena je platforma TensorFlow Lite, pisana programskim jezikom Python 3.6. Sama platforma sadrži funkcije potrebne za razvoj modela temeljenih na ML-u. Za razvoj modela za automatsko prepoznavanje odraslih oblika *P. oleae* korišten je analitički model EfficientDet-Lite 4. Scalable and Efficient Object Detection, skraćeno, EfficientDet, tip je modela za detekciju objekata. Ima mogućnost korištenja manje količine podataka za uspješnu detekciju objekata na slici, što je odgovaralo ovom istraživanju (Tan i sur., 2019).

## 4. Rezultati i rasprava

U svrhu istraživanja, fotografirano je i anotirano 157 ploča s odraslim oblicima *P. oleae*. Ukupan broj anotacija iznosi 4269, od čega 3216 anotacija pripada klasi Olive\_trap\_moth, 837 klasi Trap\_other i 216 klasi Trap\_insects\_other. Nakon provedene faze potvrde pouzdanosti razvijenog modela za automatsku detekciju maslininog moljca, rezultati su pokazali da AP vrijednost klase Olive\_trap\_moth iznosi 0.59. Za ostale klase, definirane pri izradi modela (Trap\_other i Trap\_insects\_other), rezultati su pokazali da parametar AP iznosi 0.47 i 0.38. Najveću vrijednost ima parametar AP50 – od čak 0.75, dok parametar AP75 iznosi 0.56.

U tablici 4.1. prikazani su rezultati faze potvrde pouzdanosti razvijenog modela.

Tablica 4.1. Prikaz vrijednosti<sup>1</sup> modela dobivenih u istraživanju

PARAMETAR	MODEL
<b>AP</b>	0.485473
<b>AP50</b>	0.7566532
<b>AP75</b>	0.5607391
<b>APS</b>	0.50623953
<b>APM</b>	0.49863094
<b>APL</b>	0.52043915
<b>ARMAX1</b>	0.3400753
<b>ARMAX10</b>	0.6169783
<b>ARAMX100</b>	0.6458538
<b>ARS</b>	0.55
<b>ARM</b>	0.6482749
<b>ARL</b>	0.65543556
<b>AP_OLIVE_TRAP_MOTH</b>	0.59008944
<b>AP_TRAP_OTHER</b>	0.47999007
<b>AP_TRAP_INSECTS_OTHER</b>	0.38633952

Izvor: A. Zdrilić

<sup>1</sup> AP – prosječna preciznost; AP50 – AP za IoU = 50% (parametar PASCAL VOC-a); AP75 – AP za IoU = 75%; APs – AP za male objekte površine <32<sup>2</sup>; APm – AP za srednje objekte površine 32<površina<96<sup>2</sup>; API – AP za objekte velike površine >96<sup>2</sup>; ARmax1 – AR za 1 detekciju po slici; ARmax10 – AR za 10 detekcija po slici; ARmax100 – AR za 100 detekcija po slici; ARs – AR za male objekte površine <32<sup>2</sup>; ARm – AR za srednje objekte površine 32<površina<96<sup>2</sup>; ARI – AR za velike objekte površine >96<sup>2</sup>; AP\_Olive\_trap\_moth – AP za klasu Olive\_trap\_moth; AP\_Trap\_other – AP za klasu Trap\_other; AP\_Trap\_insects\_other – AP za klasu Trap\_insects\_other

U svim fotografijama u setu za utvrđivanje pouzdanosti modela je bilo 59 % relevantnih fotografija s podacima o odraslim oblicima vrte *P. oleae*, odnosno 47 % relevantnih fotografija s podacima o ostalim kukcima i 38 % s podacima o ostalim predmetima. AP kompletног razvijenog modela, prikazan u tablici 4.1., iznosi 0.48, što znači da je 48 % slika u setu bilo je valjano za detekciju objekata na prikupljenim fotografijama ljepljivih ploča.

Rezultati potvrde pouzdanosti modela ukazuju na to da je AP u detekciji odraslih oblika moljca (Olive\_trap\_moth) bila veća od AP u detekciji objekata na slikama (Trap\_other i Trap\_insects\_other). Razvijeni model je uspješniji u prepoznavanju štetnika nego u prepoznavanju ostalih štetnika i ostalih objekata na fotografijama. Razlog tomu je činjenica da klasi Olive\_trap\_moth pripadaju samo odrasli oblici *P. oleae*, dok u klase Trap\_other i Trap\_insects\_other pripadaju razni objekti i velik broj štetnika koji se morfološki razlikuje. Za povećanje preciznosti prepoznavanja ostalih klasa, trebalo bi posebno anotirati fotografije s ostalim objektima i kukcima.

Popescu i sur. (2022) koristili su ANN za praćenje vrste *Halyomorpha halys* Stål, 1855. Jedna od mreža korištenih u njihovom istraživanju bila je i EfficientDet-D0, slična EfficientDet-Lite 4 mreži. AP50 iznosila je 0.63, a AP75 vrijednost iznosila je 0.44. Popescu i sur. (2022) koristili su fotografije s kompleksnim pozadinama, primjerice na biljkama, i uspoređivali preciznost detekcije sa fotografijama istih štetnika, ali na bijeloj pozadini. Naveli su kako EfficientDet mreža ne daje zadovoljavajuće rezultate kad su kompleksne pozadine u pitanju. Prema tome, može se zaključiti da bi i vrijednost AP modela za prepoznavanje odraslih oblika vrste *P. oleae* vjerojatno bila veća kad bi se uzimale fotografije ovog štetnika na jednostavnijim podlogama.

Čirjak i sur. (2022) u svom radu razvili su sustav za automatsko praćenje vrste *L. malifoliella* i prepoznavanje šteta koju ovaj štetnik radi u obliku mina na listu. Za razvoj sustava su također koristili EfficientDet-Lite 4 model za određivanje objekata koji se pokazao uspješan u detekciji štetnika. U istraživanju su razvijena dva modela – jedan za praćenje jedinki *L. malifoliella* (PMD – Pest Monitoring Device) i drugi za prepoznavanje mina na listu (VMD – Vegetation Monitoring Device). AP vrijednost za model za detekciju štetnika iznosio je 0.66, te 0.46 za VMD. Vrijednost AP za klasu MINERS (jedinke *L. malifoliella*) u modelu za praćenje štetnika iznosi 0.69. Vrijednost AP za klasu MINES (mine na listu) iznosila je 0.62 (Čirjak i sur., 2023). AP50 vrijednost za model za detekciju štetnika, u navedenom radu, iznosila je 0.93, a AP75 za isti model iznosio je 0.79. Uspoređujući rezultate vrijednosti AP za klase Olive\_Trap\_Moth i MINERS, moguće je uočiti da su one veće od vrijednosti AP rezultata svih

elemenata na slikama što znači da su modeli uspješniji u prepoznavanju štetnika nego u prepoznavanju ostalih elemenata slika. Oba modela najveću vrijednost postižu pri AP=50 % IoU. Model koji su razvili Čirjak i sur. (2023) ima veću AP vrijednost od modela za prepoznavanje vrste *P. oleae*, što je rezultat većeg prikupljanja i manipulacije većeg broja fotografija. Rotiranjem fotografija za 90, 180 i 270 stupnjeva, te vertikalnim i horizontalnim zrcaljenjem rubova fotografija, Čirjak i sur. (2023) dobili su veći set podataka, povećavajući tako i preciznost svog modela. Uz veći set podataka imali su i veći broj anotacija. Dok je za klasu Olive\_trap\_moth napravljeno 3216 anotacija, klasa MINERS imala je 4700 anotacija. Može se zaključiti da i broj anotacija utječe na prosječnu preciznost modela temeljenog na umjetnim neuronskim mrežama.

Hong i sur. (2020) radili su detekciju vrsta *Spodoptera litura* Fabricius 1775, *Helicoverpa assulta* Guenée, 1852 i *Spodoptera exigua* Hübner, 1808 pomoću umjetne neuronske mreže. Navode kako su najlošije rezultate vrijednosti AP imali pri detekciji *H. assulta* upravo zbog najmanje količine prikupljenih fotografija za tu vrstu (621 fotografija). Broj fotografija za vrstu *S. litura* iznosio je 1241, a za vrstu *S. exigua* 1369. AP vrijednost za *H. assulta* iznosila je 0.55 do 0.77, dok je za *S. litura* i *S. exigua* ista vrijednost iznosila 0.93 (do 0.98) te 0.81 (do 0.95). Prema tome, može se zaključiti da bi praćenje maslininog moljca u ovom istraživanju rezultiralo boljom AP vrijednosti da je broj prikupljenih fotografija i anotacija bio veći. Isto tako, Čirjak i sur. (2023) prikupili su 400 fotografija i 4700 anotacija za klasu MINERS, što je rezultiralo dobrom AP vrijednosti u istraživanju.

Uz to, Hong i sur. (2020) prikupili su 168 fotografija sa 986 anotacija koje sadrže isključivo ostale štetnike, kako bi neuronska mreža mogla bolje razlikovati štetnike koji su cilj istraživanja i one koji nisu. Ostali štetnici pripadali su klasi *Unknown*. Paralelno tomu, trebalo bi skupiti više uzoraka za klase Trap\_other i Trap\_insects\_other kako bi preciznost detekcije ovih objekata bila bolja, a time bi se poboljšala i sama AP vrijednost klase Olive\_trap\_moth jer bi neuronska mreža bila bolja u razlikovanju odraslih oblika vrste *P. oleae* od svih ostalih objekata na fotografijama.

Kao razlog lošijih rezultata u prepoznavanju *H. assulta*, Hong i sur. (2020) navode kako je savijanje krila ovog moljca pri slijetanju na ljepljivu ploču u lovka smanjivalo površinu štetnika. Postojale su velike varijacije u poziciji krila iste jedinke što je otežalo učenje umjetne neuronske mreže. Sličan problem pojavio se i kod prikupljanja uzoraka vrste *P. oleae*, gdje su odrasli oblici imali nekonzistentan položaj krila, otežavajući tako razvoj preciznijeg modela za detekciju ovog štetnika.

Liu i sur. (2022) razvili su sustav za praćenje nekoliko štetnika na pamuku. Autori su koristili ResNet V2 model za prepoznavanje objekata s 56 slojeva. Točnost prepoznavanja u njihovom istraživanju, na testnim slikama pomiješanim sa slikama iz stvarnog vremena, iznosio je 85.7 %. Isti autori ne navode konkretnu vrijednost AP za prepoznavanje štetnika, no navode kako je točnost prepoznavanja bila za 10.7 % manja kad su miješali slike iz seta za testiranje s terenskim slikama. Točnost modela pala je s povećanjem broja elemenata na slici, odnosno, model je uspješniji pri prepoznavanju samo štetnika u usporedbi sa slučajevima kad model prepoznae štetnike i ostale elemente (Liu i sur., 2022). Iz ovih podataka može se pretpostaviti da je AP za klasu prepoznavanja štetnika u njihovom istraživanju bio veći od AP za prepoznavanje ostalih elemenata. Isti uzorak pojavljuje se i u modelu za detekciju maslininog moljca. U tablici 4.1. vidljivo je da je AP za klasu u čijem je fokusu samo jedan štetnik (Olive\_trap\_moth) bio znatno veći nego u klasama koje detektiraju više različitih elemenata (Trap\_other i Trap\_insects\_other). Uz to, iz uzimajući u obzir rezultate iz istraživanja Liu i sur. (2022) i Popescu i sur. (2022), jasna je poveznica između povećane AP vrijednosti kad se radi prepoznavanje štetnika pomoću fotografija uzetim u laboratorijskim uvjetima ili s jednostavnom pozadinom. No, prema Liu i sur. (2022) vidljivo je da ta vrijednost opada čim se u model uvedu fotografije iz prirode, odnosno, fotografije s kompleksnom pozadinom. Iako se povećava vrijednost, to ne znači da će uspješnost modela u prepoznavanju štetnika biti velika i u prirodnom okruženju.

Rajput i sur. (2023) istražili su utjecaj povećanja broja uzoraka na ukupnu preciznost modela. Zaključili su kako se, AP vrijednost povećava s brojem uzoraka, no prevelik broj uzoraka, pogotovo nekvalitetnih, može ujedno i smanjiti istu vrijednost. Isti autori navode kako se, umjesto prikupljanja dodatnih podataka, IR može poboljšati manipulacijom postojećih. To znači da za dobru obradu podataka mora postojati određeni broj uzoraka i povećanjem kvalitete tih uzoraka nema potrebe za prikupljanjem dodatnih. Tako se smanjuje utrošeno vrijeme potrebno za prikupljanje uzoraka, mijenjanje lovki i feromonskih atraktanata, popravaka na kamere i slično (Rajput i sur., 2023). Osim povećanja broja fotografija i anotacija, može se zaključiti da bi poboljšana kvaliteta prikupljenih fotografija i njihova manipulacija, te ujednačenost u izgledu uzoraka na fotografijama ljepljivih ploča, uvelike povećali vrijednost AP za klase, u modelu za praćenje vrste *P. oleae*.

## 5. Zaključak

Model za automatsko prepoznavanje odraslih oblika vrste *P. oleae* razvijen je prema sljedećim koracima:

- 1) Postavljene su feromonske lovke s ljepljivim pločama za prikupljanje odraslih oblika vrste *P. oleae*;
- 2) Prikupljene ploče fotografirane su uređajem za uzimanje slikovnih podataka u svrhu stvaranja baze podataka za učenje modela;
- 3) Fotografije su anotirane, a objekti na fotografijama podijeljeni su tri klase – Olive\_trap\_moth, Trap\_other i Trap\_insects\_other;
- 4) Anotirani podaci korišteni su za učenje umjetne neuronske mreže i razvoj modela; jedan dio njih koristi se kao set za učenje, ostali dio je set za potvrđivanje pouzdanosti modela.

Na temelju dobivenih podataka može se zaključiti da je sustav učinkovit u detekciji odraslih oblika vrste *P. oleae*, no potrebno ga je dodatno unaprijediti većom količinom podataka kako bi mogao biti pouzdaniji i precizniji u detekciji ciljanih štetnika, a time korišten kao samostalni sustav za praćenje maslininog moljca. Povećanjem broja kvalitetnih fotografija i, njihovom manipulacijom bi svakako porasla i ukupna pouzdanost modela. Ovakav model mogao bi se u budućnosti prilagoditi i za praćenje ostalih štetnika masline.

S obzirom na rastući interes za maslinarstvom u Republici Hrvatskoj, potrebno je implementirati modele temeljene na umjetnim neuronskim mrežama za automatsko praćenje štetnika u zaštitu masline. Takvi sustavi omogućuju ekološko gospodarenje maslinicima jer ranom detekcijom štetnika može se pravovremeno djelovati protiv njihovog utjecaja na urod ploda, kvalitetu ulja, rast stabla i slično. Uz to, smanjenjem potrebe za korištenjem sredstava za zaštitu bilja dolazi do prijelaza na ekološku i održivu poljoprivredu.

## 6. Popis literature

1. Ahmad Supian M. B., Madzin H., Albahari E. (2019). Plant Disease Detection and Classification Using Image Processing Techniques: a review. 2nd International Conference on Applied Engineering (ICAE). Batam, Indonesia. 103-109.
2. Andreadis S., Raptis D., Konstantinou G., Savopoulou-Soultani M. (2011). Monitoring and control of the olive moth *Prays oleae* in the prefecture of Evros. Znanstveni radovi Sveučilišta u Ruseu. 40-43.
3. Basori A.H., Mansur A.B.F., Riskiawan H.Y. (2020). SMARF: smart farming framework based on big data, iot and deep learning model for plant disease detection and prevention. Applied computing to support industry: innovation and technology - first international conference 1174. Springer, Cham. 44–56.
4. Bjeliš M. (2009). Zaštita masline u ekološkoj proizvodnji II prošireno izdanje. Vlastita naklada. Solin. 142-147.
5. Camarinha-Matos L., Goes J., Gomes L., Martins J. (2013). Contributing to the Internet of Things. IFIP Advances in Information and Communication Technology 394. Springer, Berlin, Heidelberg. 3-12.
6. Cardim Ferreira Lima M., Damascena de Almeida Leandro M. E., Pereira Coronel L. C., Goncalves Bazzo C. O. (2020). Automatic Detection and Monitoring of Insect Pests – A Review. Agriculture 10(5).
7. Civantos-Ruiz M., Gómez-Guzmán J. A., Pérez M., González-Ruiz R. (2022). Application of Accumulated Heat Units in The Control of The Olive Moth, *Prays Oleae* (BERN.) (LEP., PRAYDIDAE), in Olive Groves in Southern Spain. Revista Brasileira de Fruticultura. 44(5):e-804.
8. Čirjak D., Aleksi I., Miklečić I., Antolković A. M., Vrtodušić R., Viduka A., Lemic D., Kos T., Pajač Živković I. (2023). Monitoring System for *Leucoptera malifoliella* (O. Costa, 1836) and Its Damage Based on Artificial Neural Networks. Agriculture 13. 1(67).
9. Čirjak D., Miklečić I., Lemić D., Kos T., Pajač Živković I. (2022). Automatic Pest Monitoring Systems in Apple Production under Changing Climatic Conditions. Horticulturae 8. 6(520).
10. Dahikar S.S., Rode S.V. (2014). Agricultural Crop Yield Prediction Using Artificial Neural Network Approach Miss. IJIREEICE 2(1). 683-686.

11. Dhingra G., Kumar V., Joshi H.D. (2018). Study of digital image processing techniques for leaf disease detection and classification. *Multimed Tools Appl.* 77(2). 19951–20000.
12. Fraga H., Moriondo M., Leolini L., Santos J.A. (2021). Mediterranean Olive Orchards under Climate Change: A Review of Future Impacts and Adaptation Strategies. *Agronomy* 11. 1(56).
13. Fresco R., Ferrari G. (2018). Enhancing precision agriculture by internet of things and cyber physical systems. *Atti Soc. Tosc. Sci. Nat. Mem. Suppl.* 125. 53–60.
14. Grünig M., Razavi E., Calanca P., Mazzi D., Wegner J. D., Pellissier L. (2021). Applying deep neural networks to predict incidence and phenology of plant pests and diseases. *Ecosphere, An ESA Open Access Journal* 12(10). 1-16.
15. Hong S.J.; Kim S.Y., Kim E., Lee C.H., Lee J.S., Lee D.S., Bang J., Kim G. (2020). Moth Detection from Pheromone Trap Images Using Deep Learning Object Detectors. *Agriculture* 10. 5(170).
16. Kasinathan T., Uyyala S. R. (2021). Machine learning ensemble with image processing for pest identification and classification in field crops. *Neural Computing and Applications* 33(13). 7491–7504.
17. Kos T., Šikić Z., Zdrilić A., Marcellić Š., Gašparović Pinto A., Zorica M., Franin K., Kolega Š. (2021). Tehnike analize vizualnih podataka za rano otkrivanje i klasifikaciju štetnih organizama i biljnog stresa. *Fragmenta Phytomedica* 35(7). 34-58.
18. Kumral N.A., Kovancı B., Akbudak B. (2005). Pheromone trap catches of the olive moth, *Prays oleae* (Bern.) (Lep., Plutellidae) in relation to olive phenology and degree-day models. *Journal of Applied Entomology* 129. 375-381.
19. Liu C., Zhai Z., Zhang R., Bai J., Zhang M. (2022). Field Pest Monitoring and Forecasting System for Pest Control. Sec. *Technical Advances in Plant Science* 13.
20. Maceljski M. (2002). Poljoprivredna entomologija II. Dopunjeno izdanje. Zrinski d.d. Čakovec. 286-287.
21. Nobre T., Gomes L., Rei F. T. (2018). Uncovered variability in olive moth (*Prays oleae*) questions species monophyly. *PLoS One* 13(11).
22. Osinga S.A., Paudel D., Mouzakitis S. A., Athanasiadis I.N. (2022). Big data in agriculture: Between opportunity and solution. *Agricultural Systems* 195.
23. Pascual S., Ortega M., Villa M. (2022). *Prays oleae* (Bernard), its potential predators and biocontrol depend on the structure of the surrounding landscape. *Biological Control* 176.

24. Popescu D., Ichim L., Dimoiu M., Trufelea R. (2022). Comparative Study of Neural Networks Used in *Halyomorpha Halys* Detection. 30th Mediterranean Conference on Control and Automation (MED). 182-187.
25. Potamitis I., Eliopoulos P., Rigakis I. (2017.) Automated Remote Insect Surveillance at a Global Scale and the Internet of Things. *Robotics* 6. 3(19).
26. Preti M., Verheggen F., Angeli S. (2021). Insect pest monitoring with camera-equipped traps: strengths and limitations. *Journal of Pest Science* 94. 203–217.
27. Rajput D., Wang W. J., Chen C. C. (2023). Evaluation of a Decided Sample Size in Machine Learning Applications. *BMC Bioinformatics* 24(48). 1-17.
28. Sethupathy J., Veni S. (2016). OpenCV Based Disease Identification of Mango Leaves. *International Journal of Engineering and Technology* 8. 1990-1998.
29. Shehata W., Abou-Elkhair S., Youssef A., F. N. Nassir. (2003). Biological studies on the olive leaf moth, *Palpita unionalis* Hübner (Lepid., Pyralidae), and the olive moth, *Prays oleae* Bernard (Lepid., Yponomeutidae). *AFS* 76(6). 155-158.
30. Tan M., Pang R., Le Q. V. (2019). EfficientDet: Scalable and Efficient Object Detection. ArXiv. Cornell University.
31. Theodoridis S., Kountroumbas K. (2008). Pattern Recognition 4th Ed. Academic Press, Inc. Sjedinjene Američke Države.
32. Turing A. M. (1950.) Computing Machinery and Intelligence. *Mind* 49. 433-460.
33. Wang S.C. (2003). Artificial Neural Network. In: Interdisciplinary Computing in Java Programming. The Springer International Series in Engineering and Computer Science 743. Springer, Boston. 81-100.
34. Xia D., Chen P., Wang B., Zhang J., Xie C. (2018). Insect Detection and Classification Based on an Improved Convolutional Neural Network. *Sensors* 27. 18(12). 1-12.
35. Yalcin H. (2015). Vision Based Automatic Inspection of Insects in Pheromone Traps. Conference: Fourth International Conference on Agro-Geoinformatics. Istanbul Technical University.
36. Yuan Y., Chen L., Wu H., Li L. (2022). Advanced Agricultural Disease Image Recognition Technologies: A Review. *China Agricultural University* 9(1). 48-59.

**Popis korištenih izvora – poveznica:**

Baeldung (2023). Training and Validation Loss in Deep Learning. <https://www.baeldung.com/cs/training-validation-loss-deep-learning> Pristup 20.09.2023.

COCODataset (2023). Metrics. <https://cocodataset.org/#detection-eval> Pristup 15.09.2023.

IMB (2023a). Machine Learning. <https://www.ibm.com/topics/machine-learning> Pristup 04.08.2023.

IMB (2023b). Cloud Computing. <https://www.ibm.com/topics/cloud-computing> pristup 04.08.2023.

JavaTPoint (2023). XML Tree Structure. <https://www.javatpoint.com/xml-tree-structure>. Pristup 01.08.2023.

EUROSTAT. (2023). <https://ec.europa.eu/eurostat/databrowser/view/tag00122/default/table?lang=en>. Pristup 04.08.2023.

Section (2023). Understanding PASCAL VOC Dataset. <https://www.section.io/engineering-education/understanding-pascal-voc-dataset/>. Pristup 04.08.2023.

Stanford (2023). Generalized Intersection over Union. <https://giou.stanford.edu/> Pristup 05.08.2023.

Tensorflow (2023). Module:tf.keras.metrics. [https://www.tensorflow.org/api\\_docs/python/tf/keras/metrics#modules](https://www.tensorflow.org/api_docs/python/tf/keras/metrics#modules) Pristup 05.08.2023.

## **Životopis**

Andelo Zdrilić rođen je 29.04.1997. u Zadru. Živi u mjestu Poličnik gdje je pohađao osnovnu školu i završio ju kao učenik generacije. 2011. godine upisuje gimnaziju Jurja Barakovića u Zadru, koju završava s odličnim uspjehom. Preddiplomski studij Primijenjene ekologije u poljoprivredi upisuje u akademskoj godini 2017./2018. na Sveučilištu u Zadru i završava u akademskoj godini 2019./2020. sa završnim radom na temu „Tehnike hiperspektralne analize za rano otkrivanje i klasifikaciju uzročnika biljnih bolesti“. 2021., kao jedan od koautora, objavljuje rad „Tehnike analize vizualnih podataka za rano otkrivanje i klasifikaciju štetnih organizama i biljnog stresa“ u časopisu Fragmenta Phytomedica. U akademskoj godini 2021./2022. upisuje diplomski studij Mediteranske poljoprivrede na Agronomskom fakultetu Sveučilišta u Zagrebu, smjer Povrćarstvo, aromatično, ljekovito i ukrasno bilje i završava u godini 2022./2023. Stranim jezicima se koristi u govoru i pismu, engleski na razini C1 i njemački na razini B2. Digitalno je pismen u nekoliko programskih jezika (C, HTML5, CSS3, Python), a samostalno izvršava zadatke u Microsoft Office paketu.