

**Dana ČIRJAK, Darija LEMIĆ, Ivana PAJAČ ŽIVKOVIĆ**

Sveučilište u Zagrebu Agronomski fakultet, Zavod za poljoprivrednu zoologiju  
dcirjak@agr.hr

## **DIGITALNI SUSTAVI ZA PRAĆENJE ŠTETNIKA U PROIZVODNJI JABUKE**

### **SAŽETAK**

Uvođenjem novih informacijskih tehnologija u preciznu poljoprivrednu proizvodnju razvijaju se digitalni sustavi za praćenje štetnika. Prednost je korištenja takvih sustava u pružanju informacija o prisutnosti štetnika i dinamici njegove populacije u nasadu u stvarnom vremenu, što pomaže proizvođačima u donošenju odluka o mjerama zaštite, u optimizaciji proizvodnje te pridonosi održivoj poljoprivrednoj proizvodnji. Stoga u posljednje vrijeme na tržištu raste broj razvijenih digitalnih sustava i dostupnih pametnih lovki za praćenje štetnika jabuke, posebno jabukova savijača, čija je točnost u prepoznavanju štetnika jednaka vizualnom pregledu stručnjaka. Osim jabukova savijača, korištenjem digitalnih sustava učinkovito se prate i drugi ekonomski štetnici jabuke, kao i štete, stoga bi njihovo korištenje u skoroj budućnosti moglo postati standard u proizvodnji jabuke i drugih poljoprivrednih kultura.

**Ključne riječi:** *Malus domestica* Borkh., održiva poljoprivredna proizvodnja, pametne lovke, precizna poljoprivreda, štetni kukci

### **UVOD**

Razvoj genetike, kemije i robotike uvelike je pridonio napretku poljoprivredne proizvodnje, no u suvremenu uzgoju bilja proizvođači se i dalje suočavaju sa mnogim izazovima. Suvremena proizvodnja uzrokuje anomalije u klimi te prijeti produktivnosti usjeva, zdravlju ljudi i okolišu. Istodobno, klimatske promjene postaju sve značajnije i utječu na mnoge aspekte poljoprivredne proizvodnje (npr. prinos, vrijeme berbe, biologiju štetnika i dr.) (Moretti i sur., 2010.; Skendžić i sur., 2021.). Zbog klimatskih promjena većina štetnika podložna je raznim nepravilnostima i promjenama u broju generacija te dinamici populacije (Skendžić i sur., 2021.). Zbog toga standardne metode praćenja postaju sve manje pouzdane i zahtijevaju više vremena, uz potrebu za čestim terenskim obilascima i stručnim osobljem. Nadalje, pregledavanje lovki ili biljaka na tjednoj bazi može dovesti do zakašnjelih intervencija, a bez prikupljanja informacija o dinamici populacije štetnika iznimno je teško primijeniti prikladne mjere zaštite (Preti i sur., 2021a.).

Kako bi se smanjio utjecaj klimatskih promjena na suzbijanje štetnika i kako bi se unaprijedila poljoprivredna proizvodnja, potrebno je koristiti pouzdane i

svremene metode njihova praćenja (Dong i sur., 2020.). Prikladno rješenje za takve izazove može se potražiti u tehnologijama umjetne inteligencije – "artificial intelligence"(AI). Navodnjavanje, suzbijanje korova, praćenje štetnika, i slično, u posljednje su vrijeme popraćeni umjetnom inteligencijom u kontekstu precizne poljoprivrede – "precision agriculture" (PA) (Mulla, 2013.). Precizna poljoprivreda može se definirati kao korištenje tehnologija i načela za upravljanje svim aspektima poljoprivredne proizvodnje kako bi se poboljšao prinos/urod i očuvao okoliš (Pierce i Nowak, 1999.).

S obzirom na gospodarski značaj jabuke, kao i štetnika koji znatno umanjuju isplativost uzgoja ove kulture, osnovni je cilj rada ukratko prikazati iskustva s digitalnim sustavima za praćenje štetnika, kao i sažeti informacije o komercijalno dostupnim pametnim lovckama za praćenje ključnih štetnika u jabuci, olakšavajući proizvođačima prelazak na digitalne metode praćenja.

## PREDNOSTI I NEDOSTATCI KORIŠTENJA DIGITALNIH SUSTAVA ZA PRAĆENJE ŠTETNIKA

Korištenje digitalnih tehnologija u posljednje je vrijeme zastupljeno u svim područjima života, pa tako i u poljoprivredi, što se najviše odnosi na tehnologije umjetne inteligencije (Fraser, 2019.). Suvremena poljoprivreda suočava se s velikim tehnološkim promjenama s integracijom dronova, sofisticiranih sustava za podršku odlučivanju i pametnih lovki (Fresco i Ferrari, 2018.).

Prednosti i razlozi korištenja digitalnih sustava za praćenje štetnika leže u održivoj uporabi pesticida, kao i u odgovoru na trenutačne probleme s klimatskim promjenama te svim nepravilnostima koje takve promjene uzrokuju. S obzirom na to da je poljoprivreda „tvornica na otvorenom“, pod velikim je utjecajem klimatskih promjena i njihovih posljedica (Mendelsohn, 2009.). Klimatske promjene također imaju značajan utjecaj na biologiju i ekologiju štetnih kukaca u smislu povećana broja generacija, nepravilnosti u dinamici populacije te širenja invazivnih vrsta na nova područja (Skendžić i sur., 2021.), čime je uvelike otežano njihovo praćenje. Trenutačne metode paćenja, kao i definirani pragovi odluke, rezultat su dugogodišnjeg iskustva i rada, ali nisu prilagođeni nastalim klimatskim promjenama. Ipak, svi digitalni sustavi za praćenje štetnika utemljeni su na standardnim metodama, uz poboljšanja u smislu smanjenja potrebe za ljudskim radom te mogućnosti praćenja u stvarnom vremenu. Time se monitoring i zaštita bilja prilagođavaju trenutačnim uvjetima i omogućuju ciljano suzbijanje, a proizvodnja postaje održiva. Integrirana zaštita bilja zahtjeva intenzivno praćenje usjeva/nasada, stručno osoblje i kontinuirano prikupljanje podataka. U tom kontekstu pokazalo se da je upotreba algoritama AI nužna za praćenje i korištenje dobivenih podataka, ali u optimalnom trenutku (Demirel i Kumral, 2021.).

Primjenom digitalnih metoda praćenja štetnika smanjuje se prekomjerna uporaba insekticida ali i vrijeme utrošeno na odlaske na nepristupačne terene (Rydhmer i sur., 2022.). Međutim, ovisno o metodi praćenja, feromone i ljepljive ploče potrebno je povremeno zamijeniti radi održavanja (Preti i sur., 2021a.). Uz korištenje digitalnih tehnologija, ručno brojenje i pregledavanje lovki postaju nepotrebni (Segalla i sur., 2020.). Stoga, kao odgovor na klimatske promjene, ovakvim pristupom i reduciranim brojem odlazaka na teren, dolazi do značajnog smanjenja potrošnje goriva, a time i smanjenja emisija ugljikova dioksida, čime se omogućuje povoljniji utjecaj poljoprivrede na okoliš (Pajač Živković i sur., 2020.).

Bez obzira na sve navedene prednosti i velik potencijal, kao i na komercijalnu dostupnost, ti su uređaji još uvijek nedostupni malim i srednjim proizvođačima zbog visoke cijene (Schrader i sur., 2022.). Nadalje, s obzirom na to da je digitalizacija poljoprivrede u Hrvatskoj tek u začetku, a i većina poljoprivrednih proizvođača u Hrvatskoj starije je životne dobi (Godišnje izvješće o stanju poljoprivrede u 2021. godini, 2022.), takvi su im sustavi zahtjevn za korištenje i upravljanje, pa dolazi i do njihova slabijeg prihvaćanja. Stoga je vrlo važno usmjeriti energiju na provedbu različitih edukacija u svrhu korištenja digitalnih sustava u poljoprivredi. S druge strane, korištenjem takvih sustava omogućuje se svakodnevni uvid u stanje usjeva/nasada, a time i pravodobna reakcija i ciljana primjena insekticida. Ovakvim pristupom dolazi se do smanjenja troškova zaštite, čime se ujedno nadomešta veća cijena digitalnih sustava. Odnosno, ulaganjem u digitalni sustav za praćenje štetnika kojim će se omogućiti održiva proizvodnja, smanjuju se ekonomski i ekološki gubitci prouzročeni prekomjernim korištenjem insekticida (Čirjak i sur., 2022.).

Ovakvim pristupom, odnosno implementacijom umjetne inteligencije i drugih naprednih informacijskih tehnologija u metode integrirane zaštite bilja, unaprjeđuje se monitoring štetnika i rano upozoravanje. Mogućnost detekcije štetnika u stvarnom vremenu i stvaranje digitalnih zapisa o dinamici populacije, kako prostorno, tako i vremenski, koristan je alat za rješavanje problema učinkovita praćenja štetnih kukaca u poljoprivredi (Li i sur., 2021.).

### **PRIMJENA PAMETNIH LOVKI U PROIZVODNJI JABUKE**

Jabuka je jedna od ekonomski najznačajnijih voćarskih kultura, koja se u svijetu uzgaja na skoro pet milijuna hektara (FAOSTAT, 2023.). Prilikom uzgoja takvih kultura primjenjuje se velika količina kemijskih insekticida, posebno za suzbijanje najznačajnijeg štetnika jabuke, jabukova savijača (*Cydia pomonella* L.). Budući da jabukov savijač radi štetu na plodovima jabuke i da je zahtjev tržišta proizvodnja visokokvalitetnih plodova bez simptoma nastalih od toga štetnika (Ciglar, 1998.), 70 % korištenih insekticida u nasadima jabuka koristi se za njegovo suzbijanje. Zbog toga je taj štetnik i razvio rezistentnost na nekoliko

kemijskih skupina insekticida (Ju i sur., 2021.). S obzirom na sve navedeno, javlja se potreba za korištenjem preciznijih i bržih metoda za praćenje štetnika u jabuci.

S obzirom na gospodarski značaj jabukova savijača, većina razvijenih digitalnih sustava i komercijalno dostupnih pametnih lovki za praćenje štetnika u jabuci upravo je orijentirana na toga štetnika, dok je razvoj i komercijalna dostupnost pametnih lovki za praćenje ostalih štetnika u jabuci slabije zastupljena (tablica 1).

**Tablica 1.** Komercijalno dostupne pametne lovke za praćenje štetnika jabuke (prema Čirjak i sur., 2022.)

	Štetnik	Lovka
	<i>Cydia pomonella</i> (Linneaus, 1758)	TrapView (Slovenia) SightTrap™ (USA) DTN Smart Trap (USA) iSCOUT® PHEROMONE (Austria) Semios trap (Canada)
Moljci	<i>Adoxophyes orana</i> (Fischer Röslerstamm, 1834)	CropVue trap (Canada) iSCOUT® PHEROMONE (Austria)
	<i>Zeuzera pyrina</i> (Linnaeus, 1761)	iSCOUT® PHEROMONE (Austria)
	<i>Cydia molesta</i> (Busck. 1916)	TrapView (Slovenia) Semios trap (Canada)
Stjenice	<i>Halyomorpha halys</i> (Stål, 1855)	iSCOUT® BUG (Austria)
Tripsi	<i>Frankliniella occidentalis</i> (Pergande, 1895)	iSCOUT® COLOR TRAP (Austria)
Štitasti moljci	<i>Quadraspidiotus perniciosus</i> (Comstock, 1881)	iSCOUT® PHEROMONE (Austria)
	<i>Rhagoletis pomonella</i> (Walsh, 1867)	iSCOUT® FRUIT FLY (Austria) RapidAIM (Australija)
	<i>Drosophila suzukii</i> (Matsumura, 1931)	iSCOUT® FRUIT FLY (Austria)
Voćne muhe		TrapView (Slovenia) iSCOUT® FRUIT FLY (Austria)
	<i>Ceratitis capitata</i> (Wiedemann, 1824)	TrapView (Slovenia)
Osice	<i>Hoplocampa testudinea</i> (Klug, 1816)	iSCOUT® COLOR TRAP (Austria)
	<i>Hoplocampa flava</i> (Linnaeus, 1761)	iSCOUT® COLOR TRAP (Austria)

Osim komercijalno dostupnih pametnih lovki, postoji mnogo provedenih istraživanja o razvoju digitalnih sustava za praćenje štetnika u jabuci, koji su bazirani na metodama umjetne inteligencije i umjetnih neuronskih mreža – "artificial neuron network" (ANN). Pa su tako Ding i Taylor (2016.) razvili model za detekciju jabukova savijača s fotografija štetnika snimljenih na terenu, s pomoću umjetnih neuronskih mreža. Za razvoj modela korišteno je oko 200 fotografija. Model se pokazao učinkovitim, ali je potreban veći skup podataka za razvoj kako bi model bio primjenjiviji u praksi. Razvojem tog modela, spomenuti su autori otvorili put korištenju umjetnih neuronskih mreža kao alata za detekciju štetnika u jabuci. Sütő i sur. (2021.) i Preti i sur. (2021b.) u svojim su istraživanjima predložili razvoj prototipova pametnih lovki za praćenje jabukova savijača, koje su pogodne za korištenje u ruralnim područjima jer ne zahtijevaju veliku količinu energije za rad i prijenos podataka. Pri razvoju modela autori nisu imali dovoljnu količinu prikupljenih podataka za učenje. Razvoj umjetnih neuronskih mreža obično zahtijeva veće skupove podataka kako bi se postigla dovoljna razina točnosti i pouzdanosti u detekciji.



**Slika 1.** Prototip pametne lovke u voćnjaku jabuke za praćenje jabukova savijača (Snimila: D. Čirjak)

Suárez i sur. (2021.) razvili su model baziran na umjetnim neuronskim mrežama za detekciju jabukova savijača s ukupnom točnošću detekcije od 94,8 %, a Albanese i sur. (2021.) prikupili su 4400 fotografija za razvoj modela te postigli 95-98 % točnosti u detekciji. U navedenim primjerima obrada fotografija obavljena je u samoj pametnoj lovci na terenu, a korisniku su se slali samo rezultati detekcije. Čirjak i sur. (2023a.) razvili su sustav na bazi umjetnih neuronskih mreža, koji se sastoji od pametne lovke za praćenje moljca kružnih mina (*Leucoptera malifoliella* (O. Costa, 1836)). Razvijen prototip pametne lovke također provodi obradu podataka na terenu, a rezultate detekcije šalje direktno krajnjem korisniku, čime se primjena takve lovke omogućuje i u ruralnim

sredinama. Primjer takvog prototipa pametne lovke prikazan je na slici 1. Osim toga, model implementiran u ovu pametnu lovku postiže točnost detekcije moljca kružnih mina veću od 98 %. Čirjak i sur. (2023b.) također su predstavili i pametnu lovku s implementiranim modelom za detekciju jabukova savijača koji

pokazuje točnost detekcije veću od 99 % u odnosu na vizualni pregled stručnjaka. U ovom slučaju autori su razvili pametnu lovku za praćenje više značajnih štetnika u jabuci, a model je moguće prilagoditi i za detekciju ostalih štetnika. Visoka točnost i učinkovitost pametnih lovki u praćenju navedenih štetnika ukazuje na potencijal korištenja takvih rješenja u proizvodnji jabuke u budućnosti.

## ZAKLJUČAK

Za uspješan razvoj digitalnih sustava za praćenje štetnika, utemeljenih na umjetnim neuronskim mrežama, nužan je obiman skup visokokvalitetnih podataka koji bi osigurali učinkovitost i preciznost modela u detekciji. S obzirom na gospodarski značaj jabukova savijača, većina digitalnih sustava i pametnih lovki dostupnih na tržištu bazirana je na monitoringu toga štetnika. Iz dosadašnjih iskustava u korištenju digitalnih sustava za praćenje štetnika u jabuci, nameće se zaključak da takav način monitoringa pokazuje vrlo visoku točnost, učinkovitost i brzinu u detekciji. Stoga je nužno popularizirati digitalne sustave među proizvođačima u Hrvatskoj te u budućnosti naglasiti važnost edukacije o digitalizaciji poljoprivrede. Budući da i u Hrvatskoj imamo razvijene digitalne sustave za praćenje štetnika u jabuci, s točnošću detekcije većom od 99 %, sustavi navedeni u ovom radu zasigurno će postati standard za provedbu kvalitetna i precizna monitoringa u proizvodnji jabuke.

## DIGITAL SYSTEMS FOR MONITORING PESTS IN APPLE PRODUCTION

### SUMMARY

With the introduction of new information technologies in precision agricultural production, digital systems are being developed for pest monitoring. The advantage of such systems is that they provide real-time information on the presence of pests and the dynamics of their population in the field, which helps producers make decisions on protective measures, optimize production, and contribute to sustainable agricultural production. Therefore, recently in the market there are more and more developed digital systems and available smart traps for monitoring apple pests, especially codling moth, whose accuracy in identifying pests is equal to the visual inspection of experts. In addition to codling moth, other economic apple pests, as well as damage, can be effectively monitored using digital systems, so their use may become a standard in the apple production of apples and other agricultural crops in the near future.

**Keywords:** insect pests, *Malus domestica* Borkh., precision agriculture, smart traps, sustainable agricultural production

## LITERATURA

- Albanese, A., Nardello, M., Brunelli, D. (2021.).** Automated pest detection with DNN on the edge for precision agriculture. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 11(3), 458-467.
- Ciglar, I. (1998.).** Integrirana zaštita voćaka i vinove loze. Čakovec, Zrinski d.d., 82-83.
- 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.
- Čirjak, D., Aleksi, I., Miklečić, I., Antolković, A. M., Vrtodušić, R., Viduka, A., Lemic, D., Kos T., Pajač Živković, I. (2023a.).** Monitoring System for Leucoptera malifoliella (O. Costa, 1836) and Its Damage Based on Artificial Neural Networks. Agriculture, 13(1), 67.
- Čirjak, D., Aleksi, I., Lemic, D., Pajač Živković, I. (2023b.).** EfficientDet-4 Deep Neural Network-Based Remote Monitoring of Codling Moth Population for Early Damage Detection in Apple Orchard. Agriculture, 13(5), 961.
- Demirel, M., Kumral, N.A. (2021.).** Artificial Intelligence in Integrated Pest Management. U: Artificial Intelligence and IoT-Based Technologies for Sustainable Farming and Smart Agriculture. Tomar, P., Kaur, G. (ur.). IGI Global. Pennsylvania, SAD, 289–313.
- Ding, W., Taylor, G. (2016.).** Automatic moth detection from trap images for pest management. Computers and Electronics in Agriculture, 123, 17-28.
- Dong, Y., Xu, F., Liu, L., Du, X., Ren, B., Guo, A., Zhu, Y. (2020.).** Automatic system for crop pest and disease dynamic monitoring and early forecasting. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, 4410-4418.
- FAOSTAT (2023.).** Food and Agriculture Organization of the United Nations, dostupno na: <https://www.fao.org/faostat/en/#home> (pristupljeno 3. 9. 2023.)
- Fraser, A. (2019.).** Land grab/data grab: precision agriculture and its new horizons. The Journal of Peasant Studies, 46(5), 893-912.
- Fresco, R., Ferrari, G. (2018.).** Enhancing precision agriculture by internet of things and cyber physical systems. Atti Soc. Tosc. Sci. Nat. Mem. Supplemento, 125, 53-60.
- Godišnje izvješće o stanju poljoprivrede u 2021. godini (2022.).** Ministarstvo poljoprivrede, Zagreb, Hrvatska, 23-24.
- Ju, D., Mota-Sánchez, D., Fuentes-Contreras, E., Zhang, Y. L., Wang, X. Q., rYang, X. Q. (2021.).** Insecticide resistance in the *Cydia pomonella* (L): Global status, mechanisms, and research directions. Pesticide Biochemistry and Physiology, 178, 104925.
- Li, W., Zheng, T., Yang, Z., Li, M., Sun, C., Yang, X. (2021.).** Classification and detection of insects from field images using deep learning for smart pest management: A systematic review. Ecological Informatics, 66, 101460.
- Mendelsohn, R. (2009.).** The impact of climate change on agriculture in developing countries. Journal of Natural Resources Policy Research, 1(1), 5-19.
- Moretti, C. L., Mattos, L. M., Calbo, A. G., Sargent, S. A. (2010.).** Climate changes and potential impacts on postharvest quality of fruit and vegetable crops: A review. Food Research International, 43(7), 1824-1832.

**Mulla, D. J. (2013.).** Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4), 358-371.

**Pajač Živković, I., Mirković, I., Kapuđija, D., Škorić, M., Lemić, D. (2020.).** Učinkovitost „trapview“ sustava za automatsko praćenje jabukova savijača. *Fragmenta phytomedica*, 34(6), 1-15.

**Pierce, F. J., Nowak, P. (1999.).** Aspects of precision agriculture. *Advances in agronomy*, 67, 1-85.

**Preti, M., Favaro, R., Knight, A. L., Angeli, S. (2021a.).** Remote monitoring of *Cydia pomonella* adults among an assemblage of nontargets in sex pheromone-kairomone-baited smart traps. *Pest management science*, 77(9), 4084-4090.

**Preti, M., Moretti, C., Scarton, G., Giannotta, G., Angeli, S. (2021b.).** Developing a smart trap prototype equipped with camera for tortricid pests remote monitoring. *Bulletin of insectology*, 74(1), 147-160.

**Rydhamer, K., Bick, E., Still, L., Strand, A., Luciano, R., Helmreich, S., Nikolajsen, T. (2022.).** Automating insect monitoring using unsupervised near-infrared sensors. *Scientific Reports*, 12(1), 2603.

**Schrader, M. J., Smytheman, P., Beers, E. H., Khot, L. R. (2022.).** An open-source low-cost imaging system plug-in for pheromone traps aiding remote insect pest population monitoring in fruit crops. *Machines*, 10(1), 52.

**Segalla, A., Fiacco, G., Tramarin, L., Nardello, M., Brunelli, D. (2020.).** Neural networks for pest detection in precision agriculture. U: 2020 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor). Trento, Italija, 7-12.

**Skendžić, S., Zovko, M., Pajač Živković, I., Lešić, V., Lemić, D. (2021.).** The impact of climate change on agricultural insect pests. *Insects*, 12(5), 440.

**Suárez, A., Molina, R. S., Ramponi, G., Petrino, R., Bollati, L., Sequeiros, D. (2021.).** Pest detection and classification to reduce pesticide use in fruit crops based on deep neural networks and image processing. U: 2021 XIX Workshop on Information Processing and Control (RPIC). San Juan, Argentina, 1-6.

**Sütő, J. (2021.).** Embedded system-based sticky paper trap with deep learning-based insect-counting algorithm. *Electronics*, 10(15), 1754.

## Stručni rad