

# Roboti za berbu povrtlarskih kultura

---

**Knežević, Hrvoje**

**Undergraduate thesis / Završni rad**

**2023**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:*

**Josip Juraj Strossmayer University of Osijek, Faculty of Agrobiotechnical Sciences Osijek /  
Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet agrobiotehničkih znanosti Osijek**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:151:805160>

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

*Download date / Datum preuzimanja:* **2024-11-29**



Sveučilište Josipa Jurja  
Strossmayera u Osijeku

**Fakultet  
agrobiotehničkih  
znanosti Osijek**

*Repository / Repozitorij:*

[Repository of the Faculty of Agrobiotechnical  
Sciences Osijek - Repository of the Faculty of  
Agrobiotechnical Sciences Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**  
**FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK**

Hrvoje Knežević

Preddiplomski sveučilišni studij Mehanizacija

**Roboti za berbu povrtlarskih kultura**

**Završni rad**

**Osijek, 2023.**

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**  
**FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK**

Hrvoje Knežević, apsolvent

Preddiplomski sveučilišni studij Mehanizacija

**Roboti za berbu povrtlarskih kultura**

**Završni rad**

Povjerenstvo za ocjenu i obranu završnog rada:

1. prof. dr. sc. Luka Šumanovac, predsjednik
2. doc. dr. sc. Domagoj Zimmer, mentor
3. doc. dr. sc. Željko Barač, član

**Osijek, 2023.**

## TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku  
Fakultet agrobiotehničkih znanosti Osijek  
Preddiplomski sveučilišni studij Mehanizacija

Hrvoje Knežević

Završni rad

### **ROBOTI ZA BERBU POVRTLARSKIH KULTURA**

**Sažetak:** Od radova u poljoprivrednoj proizvodnji berba povrtlarskih kultura predstavlja zahtjevan i vremenski dugotrajan proces koji je najteže izvršiti mehanizirano. Iako su početni rezultati istraživanja robota za berbu povrtlarskih kultura obećavajući, potrebno daljnje istraživanje i razvoj ove tehnologije. Postoje mnoga ograničenja dizajniranih robota kao što su npr. robot može prepoznati samo zrele plodove, ali ne i stupanj zriobe (roboti za berbu u stakleničkoj proizvodnji), robot ne prepoznaje prepreke (roboti za berbu rajčice), potreban ljudski faktor za određivanje pristupačnih smjerova, potrebna modifikacija biljaka, plod se izgubi iz videokruga robota (roboti za berbu paprike), nedovoljno učinkovit mehanizam za visinu i kvalitetu rezanja glavice (roboti za berbu zelene salate), potrebno stvaranje umjetno kontroliranog svjetla (roboti za berbu cvjetače), nedovoljno precizna detekcija plodova (roboti za berbu krastavaca), a postoji i velika mogućnost oštećivanja plodova prilikom berbe.

**Ključne riječi:** poljoprivreda, berba, roboti, povrtlarske kulture  
42 stranice, 28 slika

Završni rad je pohranjen u Knjižnici Fakulteta Agrobiotehničkih znanosti Osijeku i u digitalnom repozitoriju završnih i diplomskih radova Fakulteta Agrobiotehničkih znanosti Osijeku

## BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek  
University Graduate Studies, Course Mehanisation

Hrvoje Knežević

Graduate thesis

### **HARVESTING ROBOTS FOR VEGETABLE CROPS**

**Summary:** In agricultural production, the harvest of vegetable crops is a demanding and long-lasting process, which is the most difficult production process to achieve mechanized operations. While initial results of the robots for harvesting vegetable crops are promising, further research and development of this technology is needed. There are many limitations of designed robots such as: the robot can recognize ripe fruits, but not the degree of ripeness (robots for harvesting greenhouse crops), the robot does not recognize obstacles (pepper harvesting robots), the human factor is required to determine the best approach, crop modification is required, lost fruit from sight during visual servoing (pepper harvesting robots), lack of reliability in stem cutting height and quality (lettuce harvesting robots), artificially controlled light is required (cauliflower harvesting robots), insufficient detection of fruits (cucumber picking robots) and is a high possibility of damaging the fruits during harvesting.

**Key words:** agriculture, harvesting, robots, vegetable crops  
42 pages, 28 pictures

BSc Thesis is archived in Library of Faculty of Agrobiotechnical sciences in Osijek and in digital repository of Faculty of Agrobiotechnical sciences Osijek

## **SADRŽAJ:**

1. UVOD.....	1
2. ROBOTI ZA BERBU POVRTLARSKIH KULTURA.....	2
2.1. Roboti za berbu povrtnarskih kultura u staklenicima.....	2
2.2. Roboti za berbu sa senzorima boje.....	6
2.3. Roboti za berbu rajčice.....	9
2.4. Roboti za berbu paprike.....	11
2.5. Roboti za berbu zelene salate.....	15
2.6. Roboti za berbu brokule.....	18
2.7. Roboti za berbu cvjetače.....	22
2.8. Roboti za berbu bundeve.....	23
2.9. Roboti za berbu krastavaca.....	24
3. LIDAR TEHNOLOGIJA.....	26
4. ROBOTI: CIJENA , DOSTUPNOST I FUNKCIJA.....	33
5. ZAKLJUČAK.....	37
6. POPIS LITERATURE.....	38

## 1. UVOD

Povećanje broja ljudske populacije, smanjenje radne snage i vremenski dugotrajan proces berbe potaknuli su istraživanje primjene robota u poljoprivrednoj proizvodnji. (Tinoco, V. i sur., 2021.)

U poljoprivrednoj proizvodnji ključan je razvoj novih tehnologija, ali i primjena tehnologija razvijenih u drugim područjima koje bi se mogle koristiti u poljoprivredi uz manje preinake, a mnogi stručnjaci vjeruju kako bi napredak u znanosti i inženjeringu mogao pozitivno utjecati na mehaniziranu berbu u poljoprivrednoj proizvodnji Sparrow i sur. (2020).

Postignut je veliki napredak u sjetvi, suzbijanju korova, žetvi, apliciranju gnojiva, zaštitnih sredstava itd., ali ne i u mehaničkoj berbi plodova povrtlarskih kultura, a roboti bi mogli imati veliku ulogu u berbi zbog svoje preciznosti i učinkovitosti Islam i sur. (2022.).

Ono što predstavlja izazov u razvoju robotike u poljoprivrednoj proizvodnji je što su, za razliku od industrijske proizvodnje, u poljoprivredi objekti neujednačene veličine, različite boje i oblika, a robote za berbu povrtlarskih kultura treba prilagoditi položaju rasta, oblika i težini plodova Tinoco i sur. (2021.)

Od radova u poljoprivrednoj proizvodnji berba povrtlarskih kultura je proces koji je najteže izvršiti mehanizirano odnosno strojno. Učinkovita berba sa malim gubicima predstavlja veliki problem u agronomiji, a na tržištu je vrlo malo opreme koja bi se mogla koristiti za izradu robota za berbu povrtlarskih kultura Jianqiao i sur. (2020.). Iako su roboti za berbu istraživani dugi niz godina, u posljednjih 30 godina nije postignut gotovo nikakav napredak u ovom području što otvara prostor za nova istraživanja i razvoj tehnologije robotske berbe Klein i sur. (2019.)

## 2. ROBOTI ZA BERBU POVRTLARSKIH KULTURA

Zbog fizički zahtjevnog i vremenski dugotrajnog procesa berbe povrtlarskih kultura koje se provodi ručno, veliki značaj predstavljala bi mehanizirana berba, a iz navedenog razloga mnogi stručnjaci su se bavili proučavanjem ove problematike. Analizirani su pokusi i algoritmi robota za berbu na otvorenom i u zatvorenom prostoru, roboti za berbu sa sensorima boje, roboti za berbu rajčice, paprike, zelene salate, brokule, cvjetače, bundeve i krastavaca.

### 2.1. Roboti za berbu povrtlarskih kultura u staklenicima

Na slici 1 prikazana je staklenička proizvodnja kao primjer ekološki napredne i sigurne proizvodnje, a sastoji se od gospodarstva, bioplinskog postrojenja, solarne elektrane i staklenika koji koristi dio energije proizvedene u bioplinskom postrojenju a isto je vidljivo na slici 1. Proizvodni proces je hidroponskog tipa, što podrazumijeva kontrolu klime, navodnjavanja i uvjeta u stakleniku.



Slika 1. Staklenička proizvodnja

(Izvor: <https://www.farmersweekly.co.za/agri-technology/>)

Proizvodnja u zatvorenom prostoru je intenzivna, u staklenicima prevladavaju visoka temperatura i vlaga zraka, a zrak je zagađen kemikalijama što nepovoljno utječe na ljudsko zdravlje i predstavlja područje u kojemu bi poljoprivredni roboti imali veliki doprinos, bili bi od velikog značaja i rezultirali bi dobrim učinkom rada. Za postizanje visokog prinosa biljkama je potrebno omogućiti

dovoljnu količinu vlage i sunčeve svjetlosti, povoljne klimatske uvjete, te upotrebu gnojiva i zaštitnih sredstava. Osim povoljnih uvjeta za rast i razvoj biljaka iznimno je važno osigurati učinkovitu i pravovremenu berbu plodova, a upotreba robota za izvršavanje ove operacije smanjila bi troškove, vrijeme potrebno za berbu i količinu ljudskog rada. Petrenko i sur. (2020.)

Prilikom uzgoja u zatvorenom prostoru biljke su manje izložene bolestima i napadu štetnika što smanjuje upotrebu pesticida. Uzgoj u zatvorenim prostorima odnosno staklenicima zahtjeva puno ljudskog rada koji bi se mogao smanjiti uporabom robota prilikom berbe povrtlarskih kultura. (Chansareewittaya, 2019.)

Osim što je za rad robota važno njegovo prepoznavanje i hvatanje plodova, te navigacija, od velike važnosti i putanja kretanja robota. Za planiranje puta potrebno je odrediti put kretanja robota tijekom sakupljanja plodova prilikom kojeg će robot doći do cilja bez sudaranja sa preprekama. Ovaj zadatak je teško izvršiti kod robota zglobnog dizajna, odnosno sa mehaničkom rukom. Uporabom metode pojačanog učenja korištenjem rekurentnih neuronskih mreža moguće je rješavanje problema sa kojima se susreću roboti za berbu kao što su prepoznavanje i hvatanje plodova Petrenko i sur. (2020.), a rekurentne neuronske mreže imaju sve veću porabu u području istraživanja Yu i sur. (2019.), te u metodama predviđanja Hewamalage i sur. (2021.)

Metoda pojačanog učenja je metoda podučavanja određenog modela na principu pokušaja i pogrešaka. Ova metoda se temelji na nagradama ili kaznama koje se daju obučenom modelu. Glavni čimbenici metode pojačanog učenja su model robota i okruženje. Prilikom svakog kretanja robota on promatra parametre okruženja (koji mogu biti nepotpuni) i na osnovu tih parametara određuje koju će radnju izvršiti. Nagrada koju robot dobiva predstavlja brojčanu vrijednost koja pokazuje koliko je uspješno odnosno neuspješno izvršio neki zadatak. Dodatno, problematikom robota u poljoprivredi bavio se Zimmer i suradnici. Prema njima, za kretanje robota nužni su senzori i kontrole pomoću kojih se može kretati u nepoznatom okruženju (okruženje koje nije programirano). Glavni dijelovi svakog robota su: senzori, kontroleri (CPU-središnja jedinica za obradbu), pogon/aktuatori (pretvarači) i krajnji izvršni elementi. Prikupljeni podaci iz senzora šalju se u obliku elektroničkog signala u CPU računalo i time se omogućuje kretanje upotrebom robotskog upravljača. Često ugrađivani jeftiniji (low-cost) senzori u robotici su: mikrofoni, ultrazvučni senzor, akustični vektorski senzor, kamera, infracrveni senzor i senzor za otkrivanje određenih kemikalija i plinova, Zimmer i sur., 2020.).

Odredi se veća brojčana vrijednost za dobro izvršene zadatke koja bi robotu predstavljala nagradu i manja brojčana vrijednost koja bi predstavljala kaznu. Cilj robota je prikupiti što veći broj bodova i dobiti što veću nagradu. Ograničenje ovakvog pristupa predstavlja nosivost robota koji ne može nositi veliku količinu ubranih plodova nego se često morao vraćati na početni položaj kako bi




odložio ubrane plodove. Još jedno ograničenje je to što robot nema cijelu sliku staklenika zato što može promatrati samo one biljke koje se nalaze u jednom odjeljku staklenika. Nepotpuna vidljivost robota predstavljala je veliki problem, ali s druge strane, kada bi robot mogao vidjeti cijeli staklenik to bi produžilo i zakompliciralo obuku Petrenko. i sur. (2020.)

Start-up FarmWise koji se osnovan 2016. godine pomaže poljoprivrednicima da poboljšaju produktivnost, zdravlje ploda, čime agrikultura postaje daleko učinkovitija i profitabilnija. Također, važno je da Farm Wise predstavlja veću razinu umjetne inteligencije koja pomaže u smanjenju količine kemijskih sredstava. U budućnosti, FarmWise će vjerojatno proširiti platformu umjetne inteligencije da automatizira druge zadaće u polju agrikulture kao što je zalijevanje polja i berba usjeva (Husti, 2019.).

Na slici 2. je prikazana ilustracija staklenika koji je podijeljen u odjeljke, a svaki odjeljak obojan je drugom bojom ovisno što predstavlja, pa tako plava boja predstavlja odjeljak staklenika u kojem je robot, bijela – odjeljci sa biljkama koje nemaju ploda, zelena – biljke sa plodovima, crvena – prepreke, žuta – odjeljci koje robot može promatrati, siva – početna točka putanje robota Petrenko i sur. (2020.). U modernim staklenicima postoji velika potražnja za automatizacijom rada. Dostupnost kvalificirane radne snage koja prihvaća zadatke koji se ponavljaju u teškim klimatskim uvjetima staklenika brzo se smanjuje Boaz Arad i sur., (2020.). Rezultirajući porast troškova rada i smanjeni kapacitet izvršili su veliki pritisak na konkurentnost sektora staklenika (Comba, Gay, Piccarolo i Ricauda Aimonino, 2010.).

Na slici 2. je prikazana ilustracija staklenika koji je podijeljen u odjeljke, i pri tome svaki odjeljak obojan je drugom bojom ovisno što predstavlja. Plava boja predstavlja odjeljak staklenika u kojem je robot, bijela boja predstavlja odjeljke sa biljkama koje nemaju ploda, dok zelena boja predstavlja biljke sa plodovima. Dodatno, crvena boja predstavlja prepreke, žuta boja predstavlja odjeljke koje robot može promatrati i siva boja koja predstavlja početnu točku putanje robota.



Slika 2. Ilustracija staklenika  
(Izvor: Petrenko, V. I. i sur., 2020.)

Kretanjem kroz staklenik robot može prepoznati plodove i njihovu fazu zriobe. Svi plodovi zriju u fazama, pa tako npr. plod rajčice ima 5 faza zriobe, odnosno 5 boja plodova: zelena, svijetlo ružičasta, ružičasta, svjetlocrvena i crvena, Jongpyo i sur. (2021.).

Globalno je do sada razvijeno oko 50 robotskih sustava žetve, od kojih nijedan do danas nije uspješno komercijaliziran Bac i sur. (2014.). U prosjeku, uspješnost berbe prototipova bila je oko 66 % (vrijednosti u rasponu između 40 - 86 %), s vremenima ciklusa od 33 s po plodu (vrijednosti u rasponu između 1 s. i 227 s.)

Na početku obuke robotu su se davali jednostavniji zadaci, a kasnije, kako je učio i skupljao iskustvo, sve kompliciraniji. Inače, softver za rad robota je ključan za traženih funkcionalnosti . Većina softvera pisana su u C++ and Python, koristeći ROS Indigo koji funkcionira na *Ubuntu 14.04, Boaz, Arad i sur., (2020.).*

Glavni zadatak robota je zaobilazanje svih prepreka i vraćanje na početnu točku gdje odlaže plodove. Robot se mogao kretati u 4 smjera: naprijed, nazad, lijevo i desno. Nasumično je postavljeno 2 do 10 plodova i 5 do 20 prepreka, a također su nasumično postavljene i početne točke robota. Nakon što je robot ubrao plodove sa biljaka iz odjeljaka obojanih zelenom bojom isti se oboji bijelom bojom, odnosno označi kao odjeljak sa biljkama bez plodova Petrenko i sur., (2020.).

Osim označavanja odjeljaka bojama, robot je imao pripadajuću boju ovisno o svom kapacitetu nosivosti, odnosno kada je robot ubrao dovoljnu količinu plodova, boja mu se promijenila u tamniju (crnu) što je signal kako se treba vratiti na početnu točku i odložiti plodove. Nakon izvršene berbe robot je dobio nagradu, a zadatak se smatrao završenim. Za ulazak u odjeljke obojane crvenom

bojom, odnosno odjeljke sa preprekama robot je dobio kaznu. Ono što je ograničavajući čimbenik i što bi trebalo dalje istraživati je to što robot prepoznaje samo zrele plodove, ali ne i stupanj zrelosti plodova.

Dodatno, zbog velike varijacije tijekom i između sezona, važno je provoditi dugoročna ispitivanja u različitim uvjetima i za različite sorte usjeva (Bac i sur., 2014; Edan; Miles, 1994) i uglavnom navesti uvjete testiranja. Ako se u funkcije može uključiti i prepoznavanje stupanja zrelosti plodova robota bi se moglo obučiti da predvidi vrijeme zriobe plodova i tako postigli maksimalnu učinkovitost, Petrenko i sur., (2020.).

## **2.2. Roboti za berbu sa sensorima boje**

Karakteristike koje bi trebali imati inteligentni roboti za berbu sljedeće:

- motorni pogon
- inteligentno praćenje
- inteligentno izbjegavanje prepreka
- prepoznavanje stupnja zrelosti i
- inteligentna berba

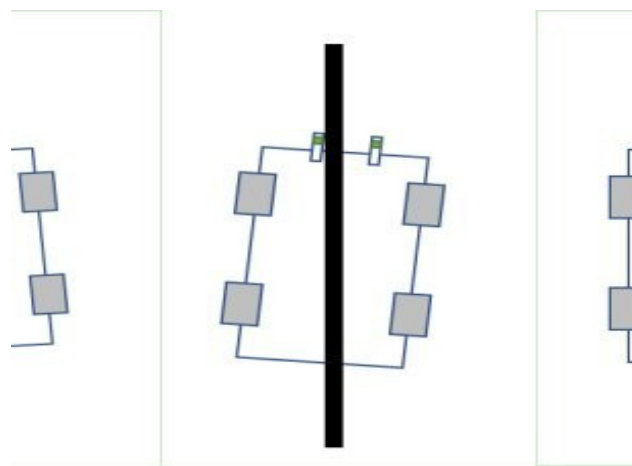
Robot za berbu sa sensorima boje sastojao bi se od motornog prijevoza inteligentnog robota, motornog pogona kontrole mehaničke ruke robota, infracrvenog senzora, čipa senzora, kamere, mehaničke ruke i mehaničke šake. Motorni pogon robota koristi se u 2 slučaja: motorni pogon za prijevoz inteligentnog robota i motorni pogon kontrole mehaničke ruke robota. Kod inteligentnog praćenja robot bi koristio infracrveni senzor kako bi stabilno i sigurno izvršavao zadatke (Jieqiong, i sur., 2021.).

Za planiranje puta robota za sakupljanje plodova potrebno je odrediti put kretanja od početne do završne točke koja neće imati prepreka, Petrenko i sur. (2020.).

Za prepoznavanje zrelosti plodova robot bi koristio senzore za boju kako bi prepoznao stupanj zrelosti plodova, zatim bi analizirao podatke koje prikupi pomoću senzora za boju. Prikupljeni podaci bi se uglavnom sastojali od RGB vrijednosti koja predstavlja crvenu, plavu i zelenu vrijednost, a na taj način robot bi odredio stupanj zrelosti plodova. Kod inteligentne berbe robotska ruka za berbu pokretala bi se motorom kako bi se postigla odgovarajuća visina i kut berbe, a plod bi brala mehanička 'šaka' koja bi pomoću hvataljke ubirala plod. Senzor boja pretvara boju u frekvenciju. U čipu senzora nalaze bi se oko 64 fotodiode koje bi bile podijeljene u četiri dijela: crveni, zeleni, plavi bezbojni filteri. Terenski pokus za berbu plodova koristio bi senzor boja koji bi

imao pravokutni oblik okružen crnom trakom. Infracrveni senzor koji bi bio ugrađen ispod inteligentnog robota za berbu identificirao bi crnu položenu liniju za praćenje, a zatim bi senzor pokretao motor koji bi se mogao kretati naprijed, nazad, lijevo i desno, Jieqiong i sur. (2021.).

Slika 3. omogućuje prikaz pozicije robota u odnosu na crnu položenu traku. Riječ je o tome da tijekom eksperimenta, sustav prvo poziva funkciju inicijalizacije infracrvenog senzora. U isto vrijeme, sljedeće četiri funkcije potrebne su za dovršetak planiranja puta robota kao što su: Skreni-lijevo (), Skreni-desno (), Kreni () i Stop (), koje uglavnom mogu kontrolirati rad robota za skretanje lijevo, desno, ići naprijed ili stati. Na primjer, kada infracrveni senzor na lijevoj strani ne prima reflektirani infracrveni signal, ali desna strana prima reflektirani infracrveni signal, mobilni robot će se pomaknuti ulijevo, a sustav treba kontrolirati mobilnog robota da se okrene desno i vratiti se u normalno stanje (Yongfeng, 2019.).



Slika 3. Pozicija robota u odnosu na crnu položenu traku

(Izvor: Jieqiong, H. i sur., 2021.)

Tijekom prohoda robota na mjestima gdje se nalaze biljke dodavale bi se crne horizontalne trake kako bi robot prepoznao položaj biljaka. Nakon što bi obadva infracrvena senzora prepoznaju crnu položenu liniju, robot bi se zaustavio i zatim bi se pokrenuo program za prepoznavanje stupnja zrelosti plodova. Program za prepoznavanje zrelosti plodova pomoću kamere u više navrata prikupljao bi podatke o boji plodova ,Jieqion. i sur. (2021.).

Plodovi povrtlarskih kultura zriju u više faza, pa tako npr plod rajčice ima 5 faza zriobe, odnosno 5 boja plodova: zelena, svijetlo ružičasta, ružičasta, svjetlocrvena i crvene, Zhang i sur. (2018.).

Prilikom pokusa odredila bi se vrijednost za zreli i za zeleni plod, a vrijednost za zreli (crveni plod) odnosno crvenu boju bila bi veća od vrijednosti za zeleni plod. Zatim bi se prikupljeni podatci analiziraju i na osnovu istih robot bi odlučio hoće li ubrati plod. Tijekom kretanja robot bi

izbjegavao, te otkrivao postoje li prepreke na njegovoj putanji. Ukoliko postoje prepreke algoritam za izbjegavanje prepreka provodio bi optimizaciju puta. Inteligentni model za berbu kontrolirao bi mehaničku ruku podešavajući kut i visinu ruke te bi pomoću mehaničke šake dosegnuo i ubrao plod.

Ovakvi roboti koristili bi dva mehanizma za upravljanje rukom, slijedi slika 4, pri čemu jedan bi upravljao položajem robotske ruke, dok drugi, mehaničkom šakom koja hvata plod. U isto vrijeme robot bi pratio crnu traku pazeći da zaobilazi prepreke, Jieqiong i sur. (2021.).



Slika 4. Robotska ruka

(Izvor: <https://uwaterloo.ca/robohub/sites/ca.robohub/>)


Podaci potrebni za odlučivanje robota o berbi mogu se prikupljati u stvarnom vremenu, a analizirajući podatke sustav može koristiti algoritam za obradu više podataka istovremeno što uvelike doprinosi odluci o pokretanju robotske ruke i berbe plodova, Jieqiong i sur. (2021.). Također, suvremeni ACRO robot može brati jabuke u komercijalnim voćnjacima pomoću vakuumske hvataljke i integrirane USB kamere. (Stajenko, 2014). Zbog upotrebe jedne ruke roboti su još relativno spori pa se u budućnosti planira napraviti sustav s više neovisnih robotskih ruku. Dok se robotska ruka približava jabuci, ponovo pomoću triangulacije i nekoliko fotografija izračunava se precizna pozicija ploda. Istovremeno puhanjem zraka kroz hvataljku plod se oslobađa lišća kako bi se mogao na kameri bolje vidjeti. Nakon što je jabuka u dohvatu ruke, aktivira se vakuumski uređaj koji jabuku okreće, naginje ili podiže te stavlja u košaru pored ruke (Stajenko, 2014).

### 2.3. Roboti za berbu rajčice

Moguća je robotska berba rajčice pomoću pojačanog učenja koja se temelji na prepoznavanju plodova pomoću 3D prikaza. Berba bi se vršila pomoću kontrole pokreta mehaničke ruke, modela hvatanja mehaničke šake i modela za rezanje koji je u obliku škara. Nakon što robot zaprimi 3D prikaz koriste se koordinate za kretanje i manipuliranje robotom. Za sorte rajčice čiji plodovi rastu u grozdovima detekcija i berba plodova je teža u odnosu na sorte rajčice sa pojedinačnim plodovima. Ključno je pažljivo hvatanje ploda rajčice kako oštar predmet (škare za rezanje) ne bi oštetio plod i tako ga učinio neprihvatljivim za komercijalne svrhe. Ova teorija testirana je na ispitnom stolu u laboratoriju, a ispitni stol napravljen je po modelu sličnom stvarnom polju rajčice. U pokusu su korištene biljke rajčice sa plodovima u obliku grozda, a svaki grozd je imao 1-4 ploda. Za utvrđivanje uspješnosti berbe u obzir je uzeto vrijeme za izvršavanje berbe, manipulacija ploda, postotak oštećenih plodova prilikom berbe, vrijeme puta i izbjegavanje prepreka prilikom kretanja robota. Vrijeme potrebno za berbu iznosilo je 5,9 sekundi, berba je izvršena relativno brzo zato što su se biljke rajčice nalazile u neposrednoj blizini robota. Broj plodova u grozdu utječe na kvalitetu berbe, odnosno teže je brati pojedinačne plodove iz grozdova sa većim brojem plodova. Utvrđeno je kako su veća oštećenja bila na grozdovima sa većim brojem plodova, dok kod pojedinačnih plodova i plodova koji su bili u grozdovima sa manjim brojem plodova oštećenja nije bilo.

Kod berbe pojedinačnih plodova uspješnost berbe iznosila je 100 %, kod berbe grozdova sa 2 ploda uspješnost berbe iznosila je 91.67 %, kod grozdova sa 3 ploda – 58.33 %, a kod grozdova sa 4 ploda – 41.67 %. Oštećenja su se događala i na plodovima u grozdu koji nisu trebali biti ubrani zbog pomicanja susjednih plodova u grozdu koji su u ovom slučaju predstavljali prepreku, Jongpyo i sur. (2021.).

Uz pomoć robotske ruke, uočeni su drugačiji rezultati berbe sa grozdovima koji imaju 1 (slučaj A), 2 (slučaj B), 3 (slučaj C) i 4 ploda (slučaj D), a isto je prikazano na slici 5.



Slika 5. Rezultati berbe sa grozdovima koji imaju 1 (slučaj A), 2 (slučaj B), 3 (slučaj) i 4 ploda (slučaj D)

(Izvor: Jongpyo, J. i sur., 2021.)

Boja ploda rajčice glavni je pokazatelj zrelosti. Plod rajčice ima 5 faza zriobe, odnosno 5 boja plodova: zelena, svijetlo ružičasta, ružičasta, svijetlocrvena i crvena. Prilikom berbe rajčice potrebno je uzeti u obzir vrijeme transporta i vrijeme skladištenja plodova. Što je plod zreliji podnosi kraće vrijeme skladištenja nakon berbe, pa je iz navedenog razloga važno poboljšati sustav klasifikacije rajčice prilikom dizajniranja robota za berbu Zhang i sur. (2018.) Kvaliteta ploda i životni vijek nakon berbe uvelike su određeni gubitkom vode iz ploda ili transpiracijom. Kod rajčice transpiracija predstavlja 92-97% gubitka mase ploda, Díaz-Pérez i sur. (2007.).

Metoda za berbu plodova rajčice temelji se na robotskom vidu. Korišteno je nekoliko načina za prikupljanje podataka u različitim fazama zriobe rajčice. Za procjenu zrelosti rajčice predložena je metoda temeljena na boji ploda gdje se sustav klasifikacije po bojama pokazao učinkovit. Osim ove metode moguća je i tehnologija strojnog učenja za automatsko prepoznavanje i sortiranje rajčice, te je dizajniran sustav klasifikacije sa poboljšanom učinkovitošću i uštedom vremena. Podaci su prikupljeni fotografiranjem, te je uslikano gotovo 200 slika plodova rajčice u 5 faza zriobe. Slike su bile u boji u uvjetima prirodne svjetlosti. Svaka faza zrelosti uključivala je preko 30 slika što je relativno mala količina podataka potrebna za učenje robota. Tijekom prikupljanja podataka u obzir su uzeti relevantni čimbenici kao što su rok trajanja ubrane rajčice i kvaliteta ploda rajčice svake faze zriobe. Ovakav način berbe rajčice u kojem bi se koristila klasifikacija plodova po fazama zriobe i metoda pojačanog učenja na temelju prikupljenih podataka u svim fazama zriobe rajčice pokazao je veliku točnost, Zhang i sur. (2018.).

Roboti bi se pokazali korisnim ne samo prilikom berbe plodova nego i zato što bi mogli prikupljati i davati kontinuirane informacije o polju, te analizirati prikupljene podatke, Oktarina i sur., (2020.).

## **2.4. Roboti za berbu paprike**

Prepoznavanje ploda smatra se jednim od ključnih ograničenja za razvoj robota za berbu. Problem prepoznavanja plodova je u tome što plodovi variraju u veličini, obliku, teksturi i položaju na biljci. Plodovi se mogu detektirati pomoću vanjskih statičkih senzora ili kamera ugrađenih u ruku robota. Nakon što kamera prepozna plod robot se počne kretati do biljke dok joj se ne približi. Ovo je važan korak zato što se pomoću njega skraćuje vrijeme berbe, a upravo je dugo vrijeme berbe glavna prepreka za komercijalni razvoj robota za berbu. Prilikom planiranja puta robota do biljke treba uzeti u obzir prepreke kao i druge biljke kako ne bi došlo do njihovog oštećenja. Kod približavanja plodu potrebno je odrediti putanju pristupa plodu koji nema lišća ispred sebe ili nekih drugih prepreka kako ne bi došlo do oštećivanja plodova, Ringdahl i sur. (2019.).

Glavni zadatak robota je zaobići sve prepreke prilikom berbe i vraćanja na početnu točku gdje bi odlagao ubrane plodove Petrenko i sur. (2020.).

Postoje dvije strategije približavanju plodu, a to su strategija jednostrukog i višestrukog pristupa. Kod jednostruke pristupne strategije robot odabire smjer koji ima najmanje prepreka. Kod višestruke strategije pristupa robot prilazi plodu iz više smjerova, te odabire najpovoljniji smjer berbe. Kada se robot približi plodu treba odlučiti je li zreo i hoće li ga ubrati ili ne. Nakon što mehanička šaka uhvati plod mora ga ubrati bez oštećenja biljke ili ploda. Pokus je izvršen u laboratoriju sa 150 plodova paprike, a platforma je postavljena u smjeru jugozapad-sjeveroistok Ringdahl i sur. (2019.).

Razlika između pokusa u stakleniku (lijeva slika) i pokusa u laboratorija (slika desno), prikazana je na slici 6. Razlike u pokusima su ukazale na to da strategija višestrukog pristupa zahtjeva više vremena za izvršavanje operacije berbe od strategije jednostrukog pristupa. Izračunata su 244 pristupa za svaki plod paprike.






Slika 6. Pokus u stakleniku (lijevo) i laboratoriju (desno)

(Izvor: Ringdahl, O. i sur., 2019.)

Strategija jednostrukog pristupa trebala je manje vremena za berbu plodova od strategije višestrukog pristupa. Od ukupno 244 pokušaja pristupa plodu, 30 pokušaja bilo je sa strategijom jednostrukog pristupa, a 214 sa strategijom višestrukog pristupa. 47 % pokušaja pristupa nije uspjelo (115 pristupa) što ukazuje na važnost određivanja pravilnog pristupa. Najčešći razlog (41 %) za neuspjeli pristup bio je što robot nije mogao pronaći siguran put do ploda, 37 % neuspjelih pokušaja bilo je zbog toga što se plod izgubio iz videokruga robota, ostalih 22 % pogrešaka se dogodilo zbog sudara robota i drugih biljaka u pokusu. Uspoređeni su rezultati pokusa u laboratoriju i stakleniku. U obadva pokusa utvrđeno je kako je strategija višestrukog pristupa zahtjeva više vremena za izvršavanje operacije berbe od strategije jednostrukog pristupa Ringdahl i sur (2019.).

Razina učinkovitosti berbe postiže se u slučaju kada čovjek određuje pristupačne smjerove. Na slici 7. prikazana su dva pristupačna smjera odnosno pristupa: višestruki i jednostruki pristup s tim da višestruki pristup zahtjeva više vremena za izvršavanje operacije berbe Ringdahl i sur. (2019.).



Slika 7. Višestruki i jednostruki pristup

(Izvor: Ringdahl, O. i sur., 2019.)

Robot je u laboratoriju uspio prići svim plodovima paprike, dok je u stakleniku pristup plodovima bio manji i iznosio je 75-95 %. Najčešći razlog neuspjelog pristupa bio je uzak prostor između biljaka u stakleniku. Analiziran je i ljudski faktor prilikom pokusa. Ljudska procjena u određivanju najboljeg pristupnog puta pokazala je visoku preciznost (92 %), a sudionici su rijetko predložili nepristupačne smjerove kao pristupačne. Iako se ljudski faktor pokazao vrlo učinkovitim, ne treba se oslanjati na čovjeka u određivanju pristupačnih puteva. Najbolja učinkovitost berbe postigla bi se kada bi čovjek odredio pristupačne smjerove i na taj način bi se postigla velika ušteda vremena pogotovo u strategiji višestrukog pristupa koji zahtjeva više vremena za izvršavanje operacije berbe, Ringdahl i sur. (2019.).

Osim prethodno navedenog, analiziran je robot za berbu paprike u stakleniku. Svaka biljka paprike sastojala se od tri stabljike, a biljke su sađene tako da tvore dvostruke redove stabljika (V-sustav, sustav usjeva u dva reda) s prosječnim razmakom od 20 cm između stabljika duž prolaza. Stabljike biljaka rastle su duž okomite potporne žice. Dizajniran je robotski sustav, a sastojao se od standardne industrijske robotske ruke, glavnog računala, senzora, druge elektroničke opreme i malog spremnika za pohranu ubranih plodova. Sva oprema bila je postavljena na kolica koja imaju dizalicu sa škarama koja može podići platformu s robotom do plodova pogodnih za berbu. Glavni računalni sustav upravljao je pogonom kolica i dizalicom sa škarama, kao i sustavom kamere i manipulatorom. Svrha mehaničke ruke robota bila je sigurno ukloniti plod sa biljke i držati ga tijekom transporta do spremnika. Mehanička ruka sadržavala je kućište za RGB-D kameru i bila je opremljena sa LED rasvjetnim tijelima. Posljednji zglob robotske ruke povezan je s navedenim kućištem pomoću nosača robotske ruke. Na vrhu kućišta bio je postavljen mehanizam za fiksiranje stabljike sa vibrirajućim nožem za rezanje peteljke ploda kojeg pokreće električni motor. Prilikom odsijecanja ploda oštrica noža bila je postavljena točno iznad peteljke ploda, a stabljika je pritom zaštićena mehanizmom za fiksiranje kako bi se spriječilo oštećenje stabljike nožem. Kada započne rezanje, pomicanjem mehaničke ruke prema dolje, mehanizam za fiksiranje se podiže, a nož započinje rezanje. Nakon što je peteljka odrezana, uređaj za hvatanje ploda držao je plod. Uređaj za hvatanje sastojao se od šest metalnih prstiju obloženih mekom plastikom Arad i sur. (2019.).

SWEEPER robot je prvi robot za berbu zrele žute paprike u komercijalnom stakleniku, slijedeći: slika 7. Namijenjen je za rad u sustavu gdje su biljke pojedinačno posađene u redove. Tijekom same berbe robot ne može istovremeno obavljati i kalibraciju plodova, dakle s pretpostavkom da plodovi budu gotovo podjednake veličine. Ruka robota opremljena je s 3D sustavom kamera, LED lampom, vibrirajućim nožem za rezanje i košarom, Sveučilište Wageningen (2022.). Preliminarni rezultati istraživanja su pokazali da robot može brati plod brzinom od 24 s točnošću od 62 % odnosno da u

roku od 24 s robot uoči papriku, te je tada s jednim nožićem odreže i potom odloži u košaru, Sveučilište Wageningen (2022.)



Slika 8. Robot za berbu paprike (SWEEPER robot)

(Izvor: Arad, B. i sur., 2019.)

Osnovna operacija bila je sljedeća: platforma se pomiče duž reda biljaka i podiže se na željenu radnu visinu. Mehanička ruka sa kamerom kreće se prema unaprijed definiranom obrascu kako bi skenirala plodove. Čim kamera detektira plod manipulator se približava plodu i određuje se položaj peteljke u odnosu na plod. Mehanička ruka zatim se okreće tako da je stabljika iza ploda, a zatim se pomiče prema plodu. Kada ruka dosegne plod, vibrirajući nož se aktivira, a mehanička ruka se pomiče prema dolje kako bi nož prezeo peteljku ploda. Plod paprike se hvata u prste montirane na mehaničkoj ruci, a manipulator se pomiče prema spremniku gdje se plod ispušta. Manipulator zatim vraća mehaničku ruku na mjesto gdje je prvi put detektiran plod, a postupak skeniranja i berba se nastavlja dok se ne ubere svi zreli plodovi. Platforma se zatim spušta na drugu razinu gdje se berba nastavlja. Kada su svi plodovi ubrani s trenutne pozicije platforme, platforma se pomiče duž tračnica do sljedeće biljke, a postupak berbe se ponavlja. Ako operacija berbe ne uspije, izvrše se najviše dva dodatna pokušaja. Ako operacija berbe i dalje ne uspije, plod ostaje na biljci. Kada platforma dođe do kraja reda biljaka, automatski se vraća na početnu točku reda. Pokus je bio proveden u stakleniku u Nizozemskoj. Prilikom pokusa korištena su 2 reda paprike, od kojih je

svaki sadržavao 100 biljaka paprike sorte Sardinero i 100 biljaka sorte Gialte. Paprika za komercijalne svrhe bere se prije pune zriobe, odnosno kada boja ploda prelazi iz zelene u žutu. Polovica biljaka od obadvije sorte modificirana je da simulira idealne okolnosti uklanjanjem listova koji su zaklanjali plod prikladan za berbu. Uklonjeni su i susjedni plodovi koji bi mogli ometati berbu. Berba plodova sa biljkama koje su posađene u 2 reda onemogućavala bi robotu pristup biljci sa svih strana i ubiranje plodova sa unutarnje strane reda, pa je pokus izveden i sa redovima paprike u 2 reda i u 1 redu. Pokus je započeo postavljanjem robota na početak reda biljaka, zatim je pokrenut i berba je započela. Nakon što je robot završio sa berbom plodova sa svih stabljika, preostali zreli plodovi koje robot nije uspio ubrati ručno su ubrani. Ukupni broj pokušaja berbe iznosio je 262 puta: 104 sa modificiranim biljkama (66 sorte Sardinero i 38 sorte Gialte) i 158 sa nemodificiranim biljkama (99 sorte Sardinero i 59 sorte Gialte). Značajno je veća uspješnost berbe kod modificiranih biljaka, u odnosu na nemodificirane (komercijalne) biljke, a uspješnost berbe također je veća kod biljaka posađenih u 1 redu u odnosu na one posađene u 2 reda. Kod biljaka posađenih u 2 reda uspješnost berbe za nemodificirane biljke iznosila je 18 %, a za modificirane 49 %. Kod biljaka posađenih u 1 redu uspješnost berbe za nemodificirane biljke iznosila je 29 %, a za modificirane 61 %. Prosječno vrijeme ciklusa do berbe ploda bilo je 24, Arad i sur. (2019.).

## **2.5. Roboti za berbu zelene salate**

Jedan od poznatih robota za berbu zelene salate je Vegebot, prikazan je na slici 9. Vegebot ima dvije glavne komponente: sustav računalnog vida i sustav rezanja. Kamera iznad glave na Vegebotu snima sliku polja salate i prvo identificira sve salate na slici. Zatim za svaku zelenu salatu robot razvrstava treba li je brati ili ne. Robot ne bere nezrelu i bolesnu salatu (Birrell, S. i sur., 2019.).



Slika 9. Robot Vegebot  
(Izvor: Birrell, S. i sur., 2019.)

Razvijen je robot za berbu Iceberg zelene salate koji je nazvan *Vegebot*, a sastojao se od vizualnog sustava (2 kamere), mehaničke ruke za berbu i upravljačkog softvera, a sve to je bilo smješteno na pokretnoj platformi. Jedna kamera bila je postavljena iznad glave na 2 m iznad tla, a druga je postavljena unutar ruke robota. Kamere omogućavaju robotu da locira i klasificira glavicu zelene salate. Ruka robota ima širok raspon pokreta. Kontrolno prijenosno računalo upravlja rukom robota koristeći dvije digitalne linije usmjerene kroz ruku robota. Mobilna platforma podržava gore navedene hardverske sustave i pomiče se po polju. Za sustav pojačanog učenja korištene su dvije integrirane konvolucijske neuronske mreže za lociranje i klasificiranje plodova. Za proces učenja prikupljaju se podaci za obuku vidnog sustava, obavlja se berba i prikupljaju dodatni podaci. Čim se prikupi dovoljno relevantnih podataka sustav se može osposobiti. Fotografije su snimljene u različitim vremenskim uvjetima, različitoj visini slikanja kamere, različitim poljima i rasporedu glavica zelene salate, različitom stupnju zriobe zelene salate i različitom kvalitetom fotografija zato što su sve ovo čimbenici koji mogu varirati tijekom berbe salate. Prilikom označavanja snimljenih fotografija označene su samo one glavice zelene salate koje su u cijelosti vidljive na fotografiji Birrell, i sur. (2019.). Slika 10. prikazuje fotografiranje polja zelene salate uz pomoć web kamere i to na različitim visinama.



Slika 10. Fotografiranje polja zelene salate web kamerom na različitim visinama  
(Izvor: Birrell, S. i sur., 2019.)

Nakon označavanja fotografija slijedi klasifikacija. Cilj klasifikacije je odabrati glavice zelene salate koje su pogodne za berbu. Sustav je testiran na terenu i dobiveni su eksperimentalni dokazi koji obećavaju uspjeh sustava za lociranje i klasifikaciju, te berbu zelene salate. Čovjek glavicu zelene salate može ubrati za 10 sekundi što se uzima kao vremenski parametar Birrell i sur.(2019.). Postupak berbe počinje tako da se robot kreće duž staze uz red zelene salate kako bi se u vidnom polju robota nalazilo otprilike 10 glavica zelene salate. Sustav vida robota detektira glavicu salate pomoću gornje kamere. Čovjek tada klikom odabire salatu. Nakon toga počinje berba, a ubrane glavice zelene salate stavljaju se na platformu. Berba se izvrši tako da se ruka robota spušta okomito prema dolje sve dok senzor ne registrira tlo. Hvatalka se aktivira i hvata glavicu zelene salate. Zatim se oštrica noža pokreće vodoravno i reže glavicu zelene salate. Tijekom pokusa sustav za vid prepoznao je 69 glavica salate pogodnih za berbu, od toga je 60 bilo u dometu robotske ruke, dok su ostale bile izvan dometa, 31 pokušaj berbe bio je uspješan, 29 pokušaja nije uspjelo, Birrell i sur. (2019.). Slika 12. prikazuje postupak pokusa na polju, na što upućuje dao neke vrste usjeva do sada nije bilo moguće brati mehanički, nego se to moralo raditi ručno. Međutim s razvojem tehnologija, otvaraju se vrata većoj automatizaciji u poljoprivredi i stoga rade se pokusi na polju, slijedi slika 1.



Slika 11. Pokus na polju  
(Izvor: Birrell, S. i sur., 2019.)

Kod nekoliko ubranih glavica salate bilo je potrebno ručno ukloniti vanjske listove kako bi bile prihvatljive zahtjevima tržišta. Kod nekih glavica salate bilo je potrebno dodatno orezivanje, razlog tomu bilo je pomicanje glavica salate prilikom odsijecanja. Većina glavica salate odrezano je preblizu glavice, pa iz navedenog razloga nisu bile prihvatljive za komercijalno tržište.

Potrebno je doraditi mehanizam rezanja glavice zelene salate kako bi ista bila upotrebljiva za komercijalno tržište. Iako se ovaj robot ne bi koristio prilikom berbe velikog broja glavica zelene salate u kratkom roku, odnosno za velike narudžbe, mogao bi biti koristan za berbu manjeg broja glavica zelene salate odnosno manjih narudžbi. Osim toga, ovaj robot mogao bi se koristiti između berbi kako bi prikupljao podatke što bi uz sustav učenja i mehanizam robotske ruke imalo potencijal za selektivnu berbu Birrell i sur. (2019.)

## 2.6. Roboti za berbu brokule

Berba brokule obavlja se selektivno i ručno u ovisnosti o veličini i stupnju zrelosti ploda kako u svježem stanju tako i za preradu u prehrambenoj industriji. Moguć pristup robotskoj berbi brokule bio bi u lociranju glavica brokule, te razvrstavanje u zelene, zrele i neupotrebljive pomoću digitalnih fotografija.

Optimalna veličina glavice prikladne za berbu u većini slučajeva je promjera 16 cm, ali s obzirom da je cilj poljoprivrednika dobiti visok prinos, što znači da se za berbu uzima u obzir veličina glavice, ali i stupanj zrelosti Garcia-Manso i sur. (2021.), slijedi slika 12.



Slika 12. Glavica brokule promjera 16 cm  
(Izvor: Garcia-Manso, A. i sur., 2021.)

Kako bi se postigao visok rinos berba s obavlja najmanje jedan puta tjedno. Snimljeno je ukupno 6165 fotografija u različitim fazama prirodnog osvjetljenja, te su klasificirane na one koje su prikladne za berbu, zelene i neupotrebljive zbog napada bolesti ili zato što su prezrele. Slike su snimane ručno sa 2 različita fotoaparata na istoj udaljenosti od tla i kamerom sa senzorom koja automatski snima više od 10 fotografija u sekundi dok se traktor kretao brzinom od 1 km/satu. Od 6165 snimljenih fotografija, njih 2778 bilo je sa glavicama prikladnim za berbu, 2805 glavica je bilo zeleno, a 582 ih je bilo neprikladno za berbu. Nakon snimanja fotografije su klasificirane i pohranjene u bazu podataka. Prilikom klasificiranja fotografija došlo je do pogrešaka, pa su npr. zelene glavice brokule klasificirane kao pogodne za berbu, glavice brokule pogodne za berbu klasificirane kao zelene, glavice brokule pogodne za berbu klasificirane kao otpad ili glavice brokule koje su za otpad klasificirane su kao pogodne za berbu Garcia-Manso i sur. (2021.). Na slici 13. prikazana je zelena glavica brokule pogodna za berbu.



Slika 13. Zelena glavica brokule klasificirana kao pogodna za berbu  
(Izvor: Garcia-Manso, A. i sur., 2021.)



Glavice brokule koje nisu pogodne za berbu odnosno klasificirane su kao zelene prikazane su na slici 14.



Slika 14. Glavica brokule pogodna za berbu klasificirana kao zelena  
(Izvor: Garcia-Manso, A. i sur., 2021.)

Snimanjem utvrđeno je koje glavice brokule se smatraju otpadom, slika 15. Izračunat je otpad 1.00.-10 %.



Slika 15. Glavica brokule pogodna za berbu klasificirana kao otpad  
(Izvor: Garcia-Manso, A. i sur., 2021.)

Slika 16 daje prikaz glavice brokule koja je klasificirana za berbu, a u biti je otpad. Pogodno za berbu iznosi 0,93 %.



Slika 16. Glavica brokule koja je za otpad klasificirana kao pogodna za berbu  
(Izvor: Garcia-Manso, A. i sur., 2021.)

Točnost procjene glavica brokule pogodnih za berbu iznosio je 97 % što je izrazito pogodno za daljnje istraživanje i implementaciju ovakvog sustava na robote za berbu brokule Garcia-Manso i sur. (2021.)

Razvijen je algoritam za prikupljanje podataka u stvarnom vremenu i prostoru, a podaci bi se mogli koristiti za daljnji razvoj i implementaciju na robotima za berbu brokule. Komponente koje robot za berbu treba imati su: sustava detekcije za prepoznavanje i lociranje plodova, sustava za berbu, fizičku manipulaciju i rezanje plodova, te navigacijski sustav koji omogućava robotu da se kreće po terenu. Ključna komponenta robota za berbu je sustav prepoznavanja za preciznu detekciju plodova i daljnju klasifikaciju zadovoljava li plod tražene parametre kvalitete (npr. veličina, boja, stupanj zrelosti). Prilikom robotske berbe brokule veliki izazov je 3D percepcija okoliša u stvarnom vremenu koja je ključna za primjenu robota za berbu. Podaci su bili prikupljeni pomoću RGB-D sensorima. Pokus na terenu izvršen je na lokacijama u Ujedinjenom Kraljevstvu i Španjolskoj. Cilj je bio razviti i demonstrirati algoritme strojnog učenja koji mogu pružiti visoku učinkovitost klasifikacije i berbe u stvarnom vremenu. U pokusu su korištena dva ista skupa podataka. Ovi skupovi podataka prikupljeni su na poljima sa brokulom pod različitim vremenskim uvjetima pomoću senzora Kinect 2 (1920×1080 RGB i rezolucije 512×424). Senzor je bio fiksiran unutar zatvorene kutije montirane na traktor radi ravnomjernog osvjetljenja i zaštite od vanjskih uvjeta Montes i sur. (2021.). Prikaz rada senzora koji je fiksiran unutar zatvorene kutije na polju prikazuje se na slici 17.



Slika 17. Kutija sa senzorom za prikupljanje podataka  
(Izvor: Montes, H. A. i sur., 2021.)

Pri istraživanju u Ujedinjenom Kraljevstvu snimljeno je 600 fotografija brokule sorte Ironman, 300 fotografija snimljeno je pri brzini od 7,5 fotografija po sekundi, a preostalih 300 snimljeno je pri brzini od 3,3 fotografije po sekundi. U istraživanju u Španjolskoj snimljeno je 300 fotografija brokule sorte Titanium pri brzini od 6,4 fotografije u sekundi. Također, pri istraživanju u Ujedinjenom Kraljevstvu fotografije su snimljene na udaljenosti od 0,29 m, a u Španjolskoj 0,34 m. Rezultati pokusa pokazali su da udaljenost senzora korištena u skupovima podataka Ujedinjenog Kraljevstva i Španjolske imaju visoku učinkovitost klasifikacije glavica brokule i berbu u stvarnom vremenu, a rezultate klasifikacije moguće je koristiti za robotsku berbu brokule. Predloženi algoritam pokazao se učinkovit budući da daje dovoljno informacija za berbu glavica brokule najpogodnijih za komercijalne svrhe. Algoritmi pokazuju potrebnu točnost detekcije i berbe plodova u stvarnom vremenu potrebnih za robotsku berbu Montes, i sur. (2021.).

## 2.7. Roboti za berbu cvjetače

Napravljen je model platforme za berbu cvjetače koji bi koristio 2 pokretljive robotske ruke koje bi radile na principu hvatanja i rezanja plodova. 3D kamere koristile bi se za praćenje rasta i stupnja zrelosti cvjetače u stvarnom vremenu. Cjelokupni proces berbe sastojao bi se iz prepoznavanja zrelih glavica cvjetače, hvatanja, odsijecanja i postavljanja na pokretnu platformu za odlaganje u ambalažu Klein i sur. (2019.). Stvaran prikaz pokretljive robotske ruke u berbi cvjetače prikazan je na slici 18.



Slika 18. Robot za berbu cvjetače  
(Izvor: Klein, F. B. i sur., 2019.)

Podaci su prikupljeni tako što je pomoću kamera svaka biljka cvjetače snimljena više puta iz više različitih kutova u različito doba dana pod različitim vremenskim uvjetima, a fotografirano je 5-10 biljaka i 3-4 različite sorte. Svaka biljka snimljena je 6 do 50 puta, a ukupno je snimljeno 1015 fotografija. Rezultati su bili kvantitativni s obzirom na veliki broj snimljenih fotografija. Prilikom testa rezanja istraživano je može li robotska ruka izvršiti pokret i odrezati glavicu cvjetače na visini od 0,3 m od tla, može li proizvesti dovoljno sile za rezanje glavice, te može li robotska ruka dohvatiti glavicu i uhvatiti je. Za rezanje glavica bilo je potrebno 15-20 sekundi. Iako su početni rezultati obećavajući potrebno je još razvijati i istraživati ovakav princip rada kako bi platforma mogla samostalno raditi. Istraživani su različiti uvjeti prirodnog osvjetljenja. Ovaj problem mogao bi se riješiti stvaranjem umjetno kontroliranog svjetla koje ne bi variralo, kao što je to slučaj sa prirodnim osvjetljenjem. Rješenje ovog problema moglo bi se nalaziti u metodi pojačanog učenja za obradu fotografija. Ova tehnika ima potencijal za poboljšanje učinkovitosti prepoznavanja stupnja zrelosti ploda. Potrebno je dodatno istražiti nosivost mehaničke robotske ruke, te poboljšati mehanizam rezanja i hvatanja Klein i sur. (2019.).

## 2.8. Roboti za berbu bundeve


Robot za berbu bundeve je dizajnirani robot koji radi na principu 'oko-ruka'. Osmišljen je na način da uključuje rad tri sustava, a to su:

1. sustav strojnog vida koji bi prepoznao plod (kamera za snimanje fotografija)
2. mehanička ruka koja bi se koristila za hvatanje i premještanje ploda

3. pokretno vozilo na kojem bi bili sustav strojnog vida i robotska ruka

Masa ploda bundeve je 3 kg ili više potrebno je razviti robotsku ruku dovoljne snage i nosivosti za berbu bundeve. Robotska ruka sastojala se od baze, pokretne poluge, spojne klipnjače i mehanizma za hvatanje ploda. Promjer robotske šake bio je 15 cm kako bi mogla ubrati plodove mase 3 kg. Yang i sur.(2020.).

Realan prikaz robotske ruke i hvataljke za berbu bundeve zorno je prikazan na slici 19.



Slika 19. Robotska ruka i hvataljka za berbu bundeve

(Izvor: Yang, L. i sur., 2020.)

Dizajn je osmišljen tako da je robotska ruka pričvršćena na stoj koji bi se kretao po polju kao što je npr. traktor ili robot. Kada kamera prepozna plod bundeve, upravljačka ruka se pomiče u potrebni položaj, hvataljka robota se otvara, polako zatvara i podiže plod bundeve Yang i sur.(2020.).

## 2.9. Roboti za berbu krastavaca

Za potrebe pokusa za projektiranje, implementaciju i provjeravanje učinkovitog sustava za prepoznavanje ploda krastavaca u poljskim uvjetima korištene su 2 kamere: tzv. Time-Of-Flight (TOS) 3D kamera (rezolucije 176x144 megapiksela) i AVT Prosilica GC2450 kamera (rezolucije 2448x2050 piksela). Predložene su dvije vrste klasifikacije snimljenih fotografija: 1. postupak klasifikacije je na temelju piksela na kojima je plod krastavca i 2. koji kombinira metodu 1. klasifikacije sa 3D rekonstrukcijom. 1. postupak se temelji na označavanju svakog piksela fotografije i grupiranju u 3 grupe ovisno o tome radi li se o plodu krastavca, listu ili pozadini. Pikseli se označavaju nakon što je identificirano da pripadaju plodu krastavca, zatim se analiziraju

preostali pikseli odnosno oni na kojima su listovi ili pozadina (Fernández, 2018.). Postupak fotografiranja ploda kamerom prikazan je na slici 20.



Slika 20. Fotografija snimljena kamerom  
(Izvor: Fernández, R., 2018.)

Slika 21. predstavlja fotografiju nakon što je obavljena klasifikacija piksela. Na slici 22. žuta boja predstavlja plod krastavca, zelena lišće, a bijela pozadinu.



Slika 21. Fotografija nakon klasifikacije piksela  
(Izvor: Fernández, R., 2018.)

Izdvojeni su podaci na kojima je plod krastavca (žuta boja), te je za svaki plod određena pozicija (područje označeno žutom bojom). Rezultati preliminarne istraživanja pokazali su izvedivost predloženog načina prepoznavanja ploda krastavca. Buduće radove treba usmjeriti preciznijem prepoznavanju i lokalizaciji ploda krastavca (Fernández, 2018.).

### 3. LiDAR TEHNOLOGIJA

U suvremenoj tehnologiji za povrtlarske kulture, posebna pozornost posvećuje se laserskoj tehnologiji koja se označava pojmom LiDAR (engl. *Light Detection and Ranging*), iako je bilo sugestija da se uvede pojam LaDAR (eng. LAser Detection and Ranging), Wehr i Lohr, (1999.), zbog navođenja da se radi o implementaciji lasera.

Zračni laserski skeneri, odnosno LiDAR sustavi, počeli su se eksperimentalno koristiti sredinom 60-tih godina prošlog stoljeća za određivanje topografije (Ackermann, 1999). Razvoj LiDAR sustava tekao je veoma sporo, prije svega, zbog njihove visoke cijene, pa su počeci razvoja vezani uz američku vojsku i njoj bliske istraživačke ustanove. Međutim, od 1997. godine pa nadalje, ovu tehnologiju preuzimaju privatne tvrtke i počinju sa serijskom proizvodnjom, tako da danas na tržištu postoji veliki broj zračnih laserskih sustava: *Leica, Optech, Riegl, Fugro, Toposys* i drugi. Geodetske tvrtke u Americi i Kanadi, kao i u Europi, brzo su prepoznale prednosti LiDAR sustava, prije svega veliku brzinu prikupljanja prostornih podataka, tako da se njihova upotreba naglo širi potiskujući klasične geodetske metode (Kujundžić, 2007.).

LiDAR (laser koji se koristi za izradu karti vegetacije) može mapirati gubitak nutrijenata vodenim tokovima i omogućiti bolja rješenja (sadnja vrbi) te može nadzirati biomasu koju proizvedu ograde i šume i izmjeriti količinu fiksiranog CO<sub>2</sub> (Nađ, 2017.).

LiDAR tehnologija je potpuno automatizirana, aktivna, uključuje optičko-mehanički postupak prikupljanja prostornih podataka dostupnih s aktualnih snimališta. Najčešće se skeniranje vrši korištenjem aviona kao platforme koja nosi skener (Gajski, 2007.). Poradi velike učestalosti mjerenja i do 200 kHz, u kratkom je vremenu moguće detaljno izmjeriti oblik površine terena i objekata na njoj (Gajski, 2007.).

LiDAR je analogan radaru, osim što se bazira na impulsima laserske svjetlosti. Trodimenzionalne koordinate (primjerice x,y,z, ili zemljopisna širina, duljina i visina) željnih objekata su izračunate iz:

- 1) Vremenske razlike između emitiranog i povratnog laserskog impulsa (Gajski, 2007.):
- 2) Kuta pod kojim se impuls otpušten
- 3) Apsolutnog položaja senzora na površini ili iznad površine Zemlje

Umjesto radio valova, LiDAR koristi mnogo kraće valne duljine elektromagnetskog spektra obično u ultraljubičastom, vidljivom, ili bliskoinfracrvenom rasponu. LiDAR tehnologija omogućuje direktnu izmjeru trodimenzionalnih struktura i terena na kojem se nalaze strukture. Ovisno o

metodologiji koja se koristi za prikupljanje podataka, dobiveni podaci mogu biti veoma gusti, na primjer, 5 točaka po metru

LiDAR tehnologija prostornog laserskog skeniranja dijeli se na:

- lasersko skeniranje iz zraka (eng. *Airborne Laser Scanning - ALS*)
- lasersko skeniranje sa zemlje (eng. *Terrestrial Laser Scanning - TLS*).

Kod *ALS* tehnologije, princip je snimanja iz zraka odnosno cijelo se područje prema potrebi nadlijeće više puta kako bi se snimilo s potrebnim brojem nizova, kako bi se osiguralo pokrivanje cjelokupnog područja izmjere i izjednačenje svih nizova u bloku, visinski i položajno, te između nizova se ostavlja preklap (Gajski, 2007.).

Tijekom leta, *ALS* sakuplja podatke sa svakog od svojih senzora posebno, u tzv. sirovom formatu, kako bi se što više reduciralo vrijeme potrebno za procesiranje i povećala propusnost i kapacitet *ALS* sustava. Poradi objedinjavanja podataka sa svih senzora, iznimno točna njihova međusobna vremenska sinhronizacija je ključna za točnost cjelovitog sustava (Gajski, 2007.).

*TLS* sustav je drugačiji od *ALS* sustava. *TLS* se instalira na vozilima poradi prikupljanja preciznih ključnih podataka. Često se koristi za promatranje autocesta pri se čemu se analizira infrastruktura ili čak prikupljaju podaci izvan ili unutar zgrada. *TLS* sustav ima dva tipa: mobilni LiDAR i statični LiDAR (Sharma, 2022.).

Još jedna zanimljivost vezana je za LiDAR tehnologiju - LiDAR se ne koristi samo za prostorno skeniranje, već i za praćenje fizikalnih procesa u atmosferi, jer omogućuje vrlo precizno mjerenje brzine, smjera kretanja i gustoće čestica u atmosferi. Ova se tehnologija obilježava kraticom DIAL (engl. *Differential Absorption LiDAR*). Skeniranje se odvija već poznatom metodom mjerenja udaljenosti i ugla do određene točke u području snimanja (Gajski, 2007.).

Detaljnija pojašnjenja o LiDAR tehnologiji mogu se pročitati u članku „LiDAR tehnologija i vizualizacija“ autorice Lukić (2017). Autorica je pojasnila da pojavom LiDAR tehnologije prostorno planiranje, geodezija, arheologija i mnoga druga područja ulaze u jedno novo razdoblje. Tim mjernim postupkom u velikoj mjeri raste brzina mjerenja i količina informacija pri istovremenom smanjenju cijena rada na terenu. LiDAR tehnologija predstavlja novo doba u prikupljanju prostornih informacija.

LiDAR sustav za prikupljanje podataka koristi (Lukić, 2017.):

-laserski senzor koji se sastoji od predajnika i prijemnika



-GPS ( Globalni pozicijski sustav) prijemnik sa točnošću koja odgovara geodetskim zahtjevima


-uređaj za Inercijalni navigacijski sustav koji određuje određuje orijentaciju (INS, engl. *Inertial Navigation System*).

Laserski uređaj je priključen na tijelo letjelice koja obično leti na visinama od nekoliko stotina metara te je princip mjerenja jednostavan. Skener emitira impulse koji se od površine snimanja reflektira natrag do instrumenta (Lukić, 2017.). Vrijeme od emitiranja do prijema signala koristi se za utvrđivanje relativne pozicije svake mjerne točke. U isto vrijeme, apsolutna pozicija senzora određuje se GPS-om, dok INS osigurava orijentaciju.

Jedna od vrsta LiDAR koja može poslužiti u skeniranju sadnje povrtlarskih kultura je batimetrijski LIDAR sustav *SHOALS* (engl. *Scanning Hydrographic Operational Airborne Lidar Survey*). *SHOALS* prikuplja prostorne podatke dna mora, rijeka, jezera i obalnih linija dna mora te koristi dvije valne duljine - 532 nm i 1064 nm iz Nd-YAG lasera. Laser od 532 nm (5 mJ green output) se zbog dobre penetracije kroz vodu koristi za izmjeru dubine, a 1 064 nm (5 mJ IR output) puls se zbog velike apsorpcije koristi za određivanje vodene površine. Točnost dubine izmjerene *SHOALS* sustavom kreće se unutar 25 cm. Postoje dva sustava: slabiji *SHOALS-1000* i novi, brži *SHOALS-3000*. *SHOALS* sustavi omogućuje brzu i kvalitetnu izmjeru velikih obalnih područja, nudeći kompletan i detaljan 3D prikaz terena, vodenih površina i terena ispod njih (Novak, 2007.).

Bespilotna letjelica ili dron na prvu zvuči kao nešto što leti po zraku i zapravo je nitko ne povezuje sa poljoprivredom, međutim danas postoji već veliki izbor dronova upravo za razne namjene u poljoprivredi (DigitalAgro, 2021.). Dron kao što je LiDAR postaje sve uobičajenija i kritičnija komponenta poljoprivrednih alata. Kod poljoprivrede i povrtlarskih kultura, LiDAR tehnologija osvjetljava površinu ciljanog područja, te mjeri reflektiranu svjetlost. Tisuće laserskih impulsa se mjeri i kombinira kako bi se dobio *Point cloud* koji predstavlja površinu mete (poljoprivredno zemljište s povrtlarskim kulturama) s visokim stupnjem preciznosti. Bit je da LiDAR primjena u poljoprivredi još se istražuju, te se otkrivaju novi slučajevi uporabe (DigitalAgro, 2021.).

Dvije su ključne mogućnosti koje se tiču rada s LiDAR tehnologijom, a iste se prikazuju na slici 22. Prva mogućnost je detaljni 3D oblaci točaka, mapiranje kontura što znači da dron opremljen LIDAR-om može pomoći u izradi 3D mapa farme u visokoj razlučivosti. Druga mogućnost je izrada konturne karte koja mogu pomoći u planiranju navodnjavanja ili ranom upozorenju na eroziju tla. Također, pomaže u izmjeri visine stabla ili nadstrešnica. Budući da laserski impulsi LiDAR-a mogu prodrijeti u gusto lišće, ova je tehnologija izvrsna za mjerenje visine stabla ili nadstrešnica (DigitalAgro, 2021.).



Slika 22. LiDAR (3D Point Cloud, mapiranje kontura)

(Izvor: DigitalAgro, 2021.)

Funkcije LiDAR s dostupnom komptabilnom kamerom jesu: M210RTK V2 i M600 PRO (matrice). Prva M210RTK odnosi se na utor za dodatnu kameru i integriranim RTK modulom, M210 RTK V2 je robusno, ali svestrano rješenje za poljprivrednika. Kroz SkyPort i DJI's Payload SDK, M210 RTK V2 može biti opremljen nizom DJI kamera i komptabilnom kamerom stranih proizvođača, što ovaj dron čini moćnim rješenjem za poljoprivrednike i istraživače (DigitalAgro, 2021.).

MATRICE 600 PR predstavlja dron s šest rotora koji može nositi malo teže terete. Može se opremiti bilo kojom DJI kamerom ili kamerom drugih proizvođača da bi se snimili zračni uvidi za poljoprivredno zemljište (DigitalAgro, 2021.).

U nastavku slijedi tablični prikaz navedenih matrica za LiDAR tehnologiju (Tablica 1).

Tablica 1. Prikaz DJI-eve dronova i njihovo mjesto na farmi

<i>FUNKCIJA</i>	<i>Matrica: M210 RTK V</i>	<i>Matrica: M600 PRO</i>
Prskanje usjeva (Gnojivo,herbicid, Fungicid,Pesticid)	<i>x</i>	<i>x</i>
Indeksi vegetacije	✓	✓
Procjena zdravlja usjeva	✓	✓
Analiza tla	✓	✓
Analiza navodnjavanja	✓	✓
Broj biljaka i procjene prinosa	✓	✓
Mjerite visinu stabla ili visinu nadstrešnica <sup>11</sup>	✓	✓
Brojanje stoke	✓	✓
Zdravlje stoke	✓	✓
Izviđanje terena	✓	✓
Fotogrametrija,izviđanje i mjerenje područja i mapiranje <sup>1</sup>	✓	✓
Detaljno 3D Modeliranje, Mapiranje kontura <sup>1 2</sup>	✓	✓
Primjena kod osiguranja	✓	✓

(izvor: <https://digitalagro.eu/wp-content/uploads/2021/08/Vodic-za-kupovinu-dronova.pdf>)

Legenda:x-nema; ✓-ima

<sup>1</sup>- Integrirani RTK

<sup>2</sup>- LiDAR

Tablica 1. pokazala je matrice koje se tiču LiDAR tehnologije. Za analizu povrtlarskih kultura, bitno je dobiti uvid u indkes vegetacije, zatim procjenu u zdravlje usjeva, analizu tla, broj biljaka i procjenu prinosa, izviđanje terena te Fotogrametrija,izviđanje i mjerenje područja i mapiranje <sup>1</sup>

Prvi LiDAR sustav uveden je 2019. godine u Hrvatskoj. Prethodno je naveden da su koristi nemjerljive, posebice, pri gospodarenju vodama, kod određivanja sliva za određeno područje, projektiranja prometnica jer daje visoko precizni prikaz terena na većem području, poljoprivredi, arheologiji, geologiji i šumarstvu. LiDAR se za sada premalo koristi u Hrvatskoj, dok

geoinformatičke tvrke sa LiDAROM u Americi i zapadnoj Europi godišnje rade preko 50 projekata (HUP, 2019.).

Panday i sur. (2020.) pružili su značajne informacije o sensorima koji se koriste za male dronove: RGB digitalni fotoaparati, multispektralni, hiperspektralni, termalni, LiDAR senzori. Prema njima, bespilotne letjelice sa više rotora imaju sposobnost vertikalnog polijetanja i slijetanja (VTOL) koja omogućava bespilotnoj letjelici da djeluje u uvjetima ograničenog prostora, oni imaju manju učinkovitost u usporedbi sa bespilotnim letjelicama sa fiksnim krilima, jer one s fiksnim krilima mogu pokriti veća polja s jednom baterijom. Također, Tsouros i sur. (2019.) pružili su informacije o elementima bespilotnih zračnih sistema u preciznoj poljoprivredi: jedan ili više bespilotnih letjelica, zemaljska upravljačka stanica, upravljački sistem dron i senzori za prikupljanje podataka.

Tipovi dronova podijeljeni su u sljedećih pet kategorija: fiksno krilo, rotacijsko krilo (bespilotni helikopter i multi-rotor), leteći baloni, lepršavo krilo i parafolijsko krilo.

Prema analizi, Tsourosa i sur. (2019.) 22% studija koristilo je bespilotne letjelice sa fiksnim krilima, 4% ih je koristilo bespilotni helikopter, a 72% ih je primijenilo bespilotne letjelice sa više rotora. Nijedno istraživanje nije koristilo leteće balone i lepršava krila u preciznoj poljoprivredi, a samo 2% primijenilo je parafinsko krilo (engl. *parafoil-wing*). Prema tome, u poljoprivredi koriste se dronovi sa više rotora. Razlog je taj što područja uglavnom nisu jako velika i ne zahtijevaju pokrivanje cijele površine brzim i fiksnim bespilotnim letjelicama. Prednosti rotirajućih bespilotnih letjelica su niži troškovi, manje brzine, lako upravljanje i sposobnost manevriranja (Tsouros i sur., 2019.).

García-Berná i sur. (2020.) su analizirali tipove spektralnih podataka korištenih u istraživanjima i naveli su da su RGB slike najpoželjniji tip (tj. 46 radova), zatim hiperspektralne slike (tj. 28 radova) i termičke (tj. 22 rada). Ostali tipovi koji se koriste su blisko infracrveni (NIR), multispektralni, spektar crvenih rubova, radar sa sintetičkim otvorom blende (SAR), LiDAR i kratkovalni.

U istraživanju Panday i sur. (2020.) raspravljalo se o sljedećim mogućnosti primjene dronova, uključujući LiDAR tehnologiju u području poljoprivrede su značajne, počevši od mogućnosti velike prostorne rezolucije ( opet ovisi o visini leta), zatim mogućnost vremenske rezolucije, što znači da može letejeti u različito vrijeme i fenofazama žitarica. Mogućnost (potencijal za 3D oblak točaka velike gustoće) koju je naveo Panday sa svojim suradnicima vrlo je važna za izradu procjene fenofaza usjeva, biomase i visine biljaka potreban je (za to treba 3D oblak točaka). Važno je da nema ograničenja u broju ljudi koji koriste LiDAR tehnologiju, što znači da poljoprivrednici mogu koristiti ovu tehnologiju, naravno, uz odgovarajuću obuku. Sve više je riječi o skalabilnosti uz jeftin

rad. Zadružna poljoprivreda pomaže reducirati troškove i podijeliti resurse. Dronovi su skalabilni i jeftini u slučaju zadružne poljoprivrede Neupane i sur.,(2015.). Tu su još dvije mogućnosti a to su: pojava platformi za obradu podataka zasnovanih na oblaku: platforme za obradu (na primjer, Microsoft Azure i algoritam strojnog učenja) te osiguranje usjeva u slučaju nevremena i drugih pojava. Kao što za svaku tehnologiju postoje prednosti, raspravlja se i o izazovima koje nude dronovi, a iste pojašnjavaju Panday i sur. (2020.). Među ključnim izazovima je limitirana nosivost, što znači da dronovi imaju ograničeni kapacitet za nošenje senzora, a lagani senzori su skupi. Drugi izazov odnosi se na nisku spektralnu rezoluciju za jeftine senzore i visoki trošak hiperspektralnih senzora: Treći izazov je u biti problem osjetljivosti na atmosferske uvjete kao što su: izmaglica, jak vjetar i padavine koje mogu imati negativan učinak na uporabu upotrebu dronova (rješenje je u ispravnom planiranju i obradi slika). Četvrti izazov je limitirana izdržljivost leta: upotreba dronova sa više rotora na velikim parcelama nije izvodljiva ali se mogu koristiti dronovi s fiksnim krilima. Peti izazov odnosi se na visoke početne troškove posjedovanja: hiperspektralni senzori unaprijeđuju kvalitetu primjene, ali su skupi u komparaciji s ostalim sensorima koji se primjenjuju u poljoprivredi. Šesti izazov je pružanje niza stručnih usavršavanja za poljoprivrednika za korištenje LiDAR tehnologije. Šesti izazov blisko je povezan sa sljedećim- sedmim izazovom a to je manjak tehničkog znanja za popravak i održavanje i nedostupnost dijelova

Abdullahi i sur. (2015.) naveli su dodatna ograničenja a to su: problemi u očitavanju prilikom ekstremnih vremenskih uvjeta te premali broj propisa o bespilotnim letjelicama. Jedan veliki problem je manjak standardiziranih troškova rada za obradu slika dronova.

Boursianis i sur. (2020.) naveli su da tehnologija uz pomoć dronova, uključujući LiDAR tehnologiju, pri čemu se svaki sustav bavi određenim postupkom uzgoja, ali integracija LiDAR tehnologije s drugim tehnologijama pri praćenju uzgojnih procesa može donijeti više koristi. Uz pomoć LiDAR tehnologije mogu se rješavati pitanja fenotipizacija na parcelama i poboljšanje kvalitete usjeva. Po drugoj strani, García-Berná i sur. (2020.) stavljaju fokus na integraciju koja podrazumijeva sve aspekte uzgojnog ciklusa.

I za kraj o LiDAR tehnologiji, Messina i Modica (2020.) pojasnili da su treba više istraživanja kako bi se pojednostavila upotreba prikupljenih podataka, jer je za daljinsko očitavanje potrebno stručno znanje o termografiji.

#### 4. ROBOTI: CIJENA , DOSTUPNOST I FUNKCIJA

U ovom poglavlju analizira se dostupnost, cijena i funkcija novih robota za poljoprivredu. Prvi od je *LettuceBot2* (druga generacija) Slijedi analiza cijene robota, dostupnosti robota i funkcije robota *LettuceBot2* uz sliku 22. koja prikazuje funkciju robota *LettuceBot2* na polju.



Slika 23. *Blue River Technology 3-row LettuceBot2*

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)

Glede testiranja, u 2020. godini, dovršena su tri terenska ispitivanja 3. generacije; uključujući pojavu selektivne plijesni koji se koristi za poboljšanje klijavosti. Po pitanju cijene robota *Blue River Technology 3-row LettuceBot2*, cijena se računa po hektaru ovisno o konfiguraciji sadnica salate, ali izjednačava se s malom premijom za ručne radne troškove.

U nastavku, analiziraju dva slijedeća proizvoda: *Agrobot SW6010* i *AGSHydro*. Proizvodi ih poduzeće: Agrobot, Huelva, Španjolska. Nadalje, analiziraju se cijena, dostupnost i funkcija *Agrobot SW6010* i *AGSHydro*, s tim da su izgled i funkcija *Agrobot harvester* prikazana na slici 23., dok je na slici 24. prikazan sustav hidroponskog uzgoja uz pomoć Agrobota.



Slika 24. Agrobot harvester

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)



Slika 25 Sustav hidroponskog uzgoja uz pomoć Agrobota

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)


Proizvodi *Agrobot SW6010* i *AGSHydro* koriste se za berbu jagoda. Robot je korišten za berbu jagoda u Oxnardu, Kaliforniji, u 2020. godini. Radilo se ispitivanje odnosno završno testiranje berbe jagoda u siječnju 2019. godine. Planira se provesti sezonsko testiranje u sljedećim godinama, počevši od 2020. godine. U nastavku slijedi analiza robota *Wall-Ye 1000* koji se koristi vinogradima s ciljem obrezivanje vinove loze. Poduzeće za proizvodnju robota *Wall-Ye 1000* nalazi se u Maconu, Francuska. Slikovni prikaz robota *Wall-Ye 1000*, u vinogradima Francuske, slijedeći: slika 25.



Slika 26. Wall-Ye 1000 Pruning Robot

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)

Robot *Wall-Ye 1000* kao što je već navedeno, koristi se za obrezivanje vinove loze. Praktična primjena odrađena je u vinogradima Francuske, ali samo uz funkciju koja označava autonomno obrezivanje. Ispitivanje za rad robota *Wall-Ye 1000* odrađeno je u 2013. godine i poslije je pušteno u prodaju. Dostupno je za prodaju ali može se koristiti kao usluga, bez kupnje. Cijena je visoka, po robotu, iznosi 30.000 američkih dolara. U Švicarskoj proizvodi se robot *ecoRobotixa* čije istoimeno poduzeće proizvodi lagane autonomne robote inicijalno za plijevljenje. Analiziraju se cijena, dostupnost i funkcija uz prikaz slike 26., koja prikazuje koncept rada robota *ecoRobotixa* na polju.



Slika 27. *ecoRobotixa* ( koncept rada na polju)

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)



Područje uporabe *ecoRobotixa* je terensko testiranje u Švicarsoj u 2016. godini; dok je sljedeće godine, točnije u 2017. godini slijedilo testiranje u Njemačkoj. Funkcija *ecoRobotixa* je kao robotska platforma za plijevljenje kultura razmaknutih redova, koja uključuje napredne algoritme za prepoznavanje korova, uključujući brze robotske ruke, naprednu senzorsku tehnologiju, visoku energetska učinkovitost i bežičnu komunikaciju. Glede ispitivanja, u 2015. godini, radilo se testiranje sa šećernom repa, ali planirano je proširenje testiranja na suncokret, kukuruz i soju. Glede dostupnosti, prvi strojevi dostupni za prodaju su od prosinca 2015. godine. Cijena robota je 15. 000 EUR (18,7 tisuća američkih dolara ) po robotu.

Zadnji robot koji je predstavljen u ovom radu odnosi se na *Energida* robot koji služi za povlačenje agruma na poljima. Poduzeće koje se bavi proizvodnjom *Energida* robota smješteno je u Cambridgeu, Ujedinjeno Kraljevstvo. Slika 27 prikazuje rad *Energida* na poljima.



Slika 28. Prikaz rada *Energida* (povlačenje većeg broja agruma)

(Izvor: <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/>)

Prvobitno područje uporabe robota *Energida* bilo je za agrumi u Floridi, Sjedinjene Američke Države. Uz pomoć robota bralo se voće naranče (rana i kasna sezona) i voće grejp. Funkcija rada robota *Energida* odnosi se na berbu, u početku za sok. Planirano je i izvršeno novo testiranje robota *Energida* koje se pokazalo uspješnim u 2015. i 2016. godini. Nakon uspješnog ispitivanja, prvi roboti *Energida* pušteni su na tržište i to u studenom i prosincu 2016. godine. Cijena robota *Energida* je između 300,000 američkih dolara do 400,000 američkih dolara.

## 5. ZAKLJUČAK

U završnom radu analiziran je princip rada robota za berbu povrtlarskih kultura. Zajednička komponenta istraživanja bila je izgled robota koji bi se sastojao od mehanizma za kretanje robota kroz prostor, odnosno između biljaka, mehaničkog vida koji bi se koristio za prepoznavanje plodova na biljci, te mehaničke pokretne ruke i mehaničke šake koje bi služile za ubiranje plodova.

Iako postoje mnoge prednosti korištenja ovakve tehnologije kao što su povećanje opsega rada, smanjenje vremena potrebnog za obavljanje berbe, smanjenje ljudskog rada posebno u teškim i nepredvidivim uvjetima, kao i neposredno nakon tretiranja usjeva kemijskim sredstvima postoje potencijalni nedostaci koji se trebaju otkloniti poput malog videokrug robotskog oka, oštećivanje plodova prilikom berbe, ne prepoznavanje prepreka prilikom prohoda.

Robotska berba u Republici Hrvatskoj manje je zastupljena nego u drugim državama članicama Europske Unije iz razloga što je u Republici Hrvatskoj niži socioekonomski status poljoprivrednika, ali ova tehnologija u budućnosti bi trebala biti više zastupljena zahvaljujući financiranju iz EU fondova.

## 6. POPIS LITERATURE

1. Abdullahi, H. S., Mahieddine, F., & Sheriff, R. E. (2015.). Technology impact on agricultural productivity: A review of precision agriculture using unmanned aerial vehicles. In International conference on wireless and satellite systems (pp. 388-400). Springer, Cham
2. Ackermann, F. (1999): Airborne laser scanning - present status and future expectations. ISPRS Journal of Photogrammetry & Remote Sensing 54, pp. 64-67
3. Arad, B.; Balendonck, J.; Barth, R.; Ben-Shahar, O.; Edan, Y.; Hellström, T.; Hemming, J.; Kurster, P.; Ringdahl, O.; Tielen, T. i Tuijl, B.v. (2019.): Development of a sweet pepper harvesting robot. *Journal of Field Robotics* 37 (6): 1027-1039
4. Bac, C. W., van Henten, E. J., Hemming, J., & Edan, Y. (2014). Harvesting robots for high-value crops: State-of-the-art review and challenges ahead. *Journal of Field Robotics*, 31, 888– 911. Wiley Online LibraryWeb of Science®Google Scholar
5. Birrell, S.; Hughes, J.; Cai, J. Y.; Iida, F. (2019.): A field-tested robotic harvesting system for iceberg lettuce. *Journal of Field Robotics* 37 (2): 225-245
6. Boaz Arad, Jos Balendonck, Ruud Barth, Ohad Ben-Shahar, Yael Edan, Thomas Hellström, Jochen Hemming, Polina Kurtser, Ola Ringdahl, Toon Tielen, Bart van Tuijl Development of a sweet pepper harvesting robot (2020). *Journal of Field Robotics* Volume 37, Issue 6
7. Boursianis, A. D., Papadopoulou, M. S., Diamantoulakis, P., Liopa-Tsakalidi, A., Barouchas, P., Salahas, G., & Goudos, S. K. (2020.). Internet of Things (IoT) and Agricultural Unmanned Aerial Vehicles (UAVs) in Smart Farming: A Comprehensive Review. *Internet of Things*
8. Carter J., Schmid K., Waters K., Betzhold L., Hadley B., Mataosky R., Halleran R., 2012: National Oceanic and Atmospheric Administration (NOAA) Coastal Services Center. “Lidar 101: An Introduction to Lidar Technology, Data, and Applications.” Revised. Charleston: 3 str
9. Chansareewittaya, S. (2019). Automatic Hydroponic Harvesting Robot *Journal of Field Robotics* 25(1)
10. Comba, L., Gay, P., Piccarolo, P., & Ricauda Aimonino, D. (2010). Robotics and automation for crop management: Trends and perspective. International Conference Ragusa SHWA2010, 471- 478. Google Scholar
11. Díaz-Pérez, J. C.; Muy-Rangel, M. D. i Mascorro, A. G. (2007): Fruit size and stage of ripeness affect postharvest water loss in bell pepper fruit (*Capsicum annuum* L.). *Journal of the Science of Food and Agriculture*, 87(1): 68-73

12. Edan, Y., & Miles, G. E. (1994). Systems engineering of agricultural robot design. *IEEE Transactions on Systems, Man, and Cybernetics*, 24, 1259– 1265. [Crossref](#) [Web of Science](#) [Google Scholar](#)
13. Fernández, R., Aliende, V., Gonzalez-De-Santos, P., Armada, M., Surdilovic, J., & Surdilovic, D. (2018): Cucumber Detection For Precision Agriculture Applications. *Memorias De Congresos UTP*, 1(1), 167-174. <https://revistas.utp.ac.pa/index.php/memoutp/article/view/1903>
14. Gajski, D. (2007). Osnove laserskog skeniranja iz zraka. *Ekscentar*, (10), 16-22. Preuzeto s <https://hrcak.srce.hr/20672>
15. García-Berná, J. A., Ouhbi, S., Benmouna, B., García-Mateos, G., Fernández-Alemán, J. L., & Molina-Martínez, J. M. (2020.). Systematic Mapping Study on Remote Sensing in Agriculture. *Applied Sciences*, 10(10), 3456
16. Garcia-Manso, A.; Gallardo-Caballero, R.; Garcia-Orellana, C. J.; Gonzalez-Valasco, H. M.; Macias-Macias, M. (2021.): Towards selective and automatic harvesting of broccoli for agri-food industry. *Computers and Electronics in Agriculture* 188
17. Hewamalage, H., Bergmeir, C., & Bandara, K. (2021): Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1):388-427
18. Husti, I. (2019) Possibilities of Using Robots in Agriculture. *Hungarian agricultural engineering*, 35. pp. 59-67. ISSN 0864-7410
19. Islam, Sk. F.; Uddin, M. S.; Bansal, J. C. (2022.): *Computer Vision and Machine Learning in Agriculture* (2): 1-13
20. Jieqiong, H.; Leian, L.; Haojie; Z. (2021.): Design and implementation of intelligent agricultural picking mobile robot based on color sensor. *Journal of Physics: Conference Series*, Volume 1757, International Conference on Computer Big Data and Artificial Intelligence (ICCBDAI 2020) 24-25 October 2020, Changsha, China
21. Jianqiao, W.; Shengzhe, F.; Liang, G.; Jin, Y.; Qiang, Z.; Chengliang, L. (2020.): Research Status and Development Direction of Design and Control Technology of Fruit and Vegetable Picking Robot System. *Smart Agriculture* (2): 17-40
22. Jongpyo, J.; Jeonign, K.; Jeahwi, S.; Jeongeun K.; Hyoung S. (2021.): Towards an Efficient Tomato Harvesting Robot: 3D Perception, Manipulation, and End-Effector. *IEEE Access* (9): 17631 – 17640
23. Klein, F. B.; Wilmot, A.; De Tejada, V.F.; Rodriguez, B. L.; Requena, J.; Busch, S.; Rondepierre, A.; Auzeeri, T.; Sauerwald, T.; Andrews, W. F. P.; Rihan, H.; Fuller M. P.; Stoelen, M. F. (2019.):

- Proof of concept modular robot platform for cauliflower harvesting. *Precision Agriculture* :783 – 789
24. Kujundžić D. (2007): Zračni laserski skeneri LEICA ALS50-II i Corridor Mapper, Ekscentar, no. 10, pp. 31-34
25. Messina, G., & Modica, G. (2020.). Applications of UAV Thermal Imagery in Precision Agriculture: State of the Art and Future Research Outlook. *Remote Sensing*, 12(9), 1491
26. Montes, H. A.; Le Louedec, J.; Cielniak, G. i Duckett, T. (2021.): Real-time detection of broccoli crops in 3D point clouds for autonomous robotic harvesting. *IEEE*: 10483-10488
27. Nađ N. (2017). Spas irske poljoprivrede u okolišnoj praksi- Agroklub
28. Novak, Z. (2007). Optech LiDAR. Ekscentar, (10), 24-30. Preuzeto s <https://hrcak.srce.hr/20673>
29. Neupane, H., Adhikari, M., & Rauniyar, P. B. (2015). Farmers' perception on role of cooperatives in agriculture practices of major cereal crops in Western Terai of Nepal. *Journal of the Institute of Agriculture and Animal Science*, 177-186
30. Oktarina, Y., Dewi, T., Risma, P. i Nawawi, M. (2020): Tomato harvesting arm robot manipulator; a pilot project. In *Journal of Physics: Conference Series*. IOP Publishing
31. Panday, U. S., Pratihast, A. K., Aryal, J., & Kayastha, R. B. (2020.). A Review on Drone-Based Data Solutions for Cereal Crops. *Drones*, 4(3), 41
32. Petrenko, V. I.; Tebueva, F. B.; Gurchinsky, M. M.; Antonov, V. O. (2020.): A robotic complex control method based on deep reinforcement learning of recurrent neural networks for automatic harvesting of greenhouse crops. *Proceedings of the 8th Scientific Conference on Information Technologies for Intelligent Decision Making Support*: 340-346
33. Ringdahl, O.; Kurtser, P., Edan, Y. (2019.): Evaluation of approach strategies for harvesting robots: Case study of sweet pepper harvesting. *Journal of Intelligent & Robotic Systems* (95): 149–164
34. Sharma S. (2022.). What is LiDAR technology and how does it work? *Geospatial world*
35. Sparrow, R.; Howard, M. (2020.): Evaluation of approach strategies for harvesting robots: Case study of sweet pepper harvesting." *Journal of Intelligent & Robotic Systems*,:149-164
36. Stajanko, D. (2014). Strojevi za pomoć u berbi jabuka - stanje i perspektive. *Glasnik Zaštite Bilja*, 37 (5), 14-19. Preuzeto s <https://hrcak.srce.hr/162607>
37. Tinoco, V.; Silva, M. F.; Santos, F. N.; Rocha, L. F.; Magalhaes S.; Santos, L. C. (2021.): *IEEE International Conference on Autonomous Robot Systems and Competitions* :155-160
38. Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019.). A review on UAV-based applications for precision agriculture. *Information*, 10(11), 349.

39. Yang, L.; Tian, R.; Wang, Q.; Hoshino, Y.; Yang, S. i Cao, Y. (2020.): Optimal design and simulation of a robot hand for a robot pumpkin harvesting system. *International Robotics & Automation Journal*
40. Yongfeng, G (2019): Control and simulation of electric servo steering gear *Computing Technology and Automation* pp 60-63
41. Yu, Y.; Si, X.; Hu, C. i Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270
42. Zhang, , L.; Jia, J.; Gui, G.; Hao, X.; Gao, W. i Wang M. (2018.): Deep Learning Based Improved Classification System for Designing Tomato Harvesting Robot. *IEEE Access* (6): 67940-67950
43. Zimmer, D. Jurišić M., Plaščak, Radočaj D Primjena robota i robotskih sustava u poljoprivrednoj praksi Fakultet agrobiotehničkih znanosti Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku
44. Wehr, A., Lohr, U. (1999): Airborne laser scanning—an introduction and overview, *ISPRS Journal of Photogrammetry & Remote Sensing* 54, 1999., pp. 68-82

#### Poveznice sa interneta

1. DigitalAgro (2021) <https://digitalagro.eu/wp-content/uploads/2021/08/Vodic-za-kupovinu-dronova.pdf> (2.2.2023.).
2. HUP. Hr *Leteci LiDAR* (2019.). <https://www.hup.hr/leteci-lidar.aspx> (2.2.2023.).
3. Qingzhou Rainbow Modern Agriculture Development Co., Ltd. PC Greenhouse <https://www.farmersweekly.co.za/agri-technology/farming-for-tomorrow/latest-trends-in-greenhouse-technology/> (12.05.2022.)
4. Sveučilište Wageningen (2022). SWEEPER. <https://www.wur.nl/en/project/sweeper-the-sweet-pepper-harvesting-robot.htm> (12.11.2022.)
5. RoboHub. Robots 08. 09. 2020 <https://uwaterloo.ca/robohub/sites/ca.robohub/files/styles/sidebar-220px-wide/public/uploads/images/7-dof-spherical.jpg?itok=iMwcGhLA> (07.06.2022.)
6. Telegram hr. Ovaj gospodin prije 19 godina ostao je bez posla. Danas je jedan od najvećih proizvođača povrća u zemlji. 08. 06. 2018. <https://www.telegram.hr/wp-content/uploads/2018/06/92A1737.jpg> (07.06.2022.)
7. Tobe F November 18, 2014. Are ag robots ready? 27 companies profiled <https://www.therobotreport.com/are-ag-robots-ready-27-companies-profiled/> (26.10.2022)

8. Vegebot Report . <https://www.therobotreport.com/vegebot-robot-applies-machine-learning-harvest-lettuce/> (11.12.2022)