

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Leticija Crnković, Antonio Čogelja

BerryBot: Autonomni podatni robotski sustav za berbu malina

Zagreb, 2025.

Ovaj rad izrađen je u Laboratoriju za robotiku i inteligentne sustave upravljanja na Fakultetu elektrotehnike i računarstva pod vodstvom izv. prof. dr. sc. Matka Orsaga te asistentice mag. ing. Jelene Vuletić i predan je na natječaj za dodjelu Rektorove nagrade u akademskoj godini 2024./2025. Zahvaljujemo Regionalnom centru izvrsnosti za robotske tehnologije, CRTA-i, na ustupljenom prostoru i opremi, osobito na mogućnosti rada s robotskom rukom, što je uvelike doprinijelo realizaciji ovog rada.

SADRŽAJ

1. Uvod	1
2. Teorijska osnova	3
2.1. Podatne hvataljke	3
2.2. Senzor savijanja	4
2.3. Dubinska kamera i kalibracija	5
2.4. Robotska ruka i primjene	7
2.5. Robotski operacijski sustav	9
3. Izrada hvataljke	11
3.1. Zahtjevi za hvataljku	11
3.2. Model hvataljke	12
3.3. Prenamjena hvataljke	14
3.4. Karakterizacija hvataljke	16
4. Detekcija malina na slici	18
4.1. Izolacija pomoću boje	18
4.2. Optimiranje poze hvatanja	20
5. Autonomni robotski sustav: BerryBot	22
5.1. Simulacijsko okruženje	23
5.1.1. Konfiguracija simulacijskog modela robota	24
5.2. Stvarno okruženje	26
5.2.1. Izrada i testiranje sustava	26

5.3. Upravljanje robotskim sustavom	28
5.3.1. Propriocepcija	29
5.3.2. Eksterocepcija	29
5.3.3. Upravljanje manipulatorom	30
5.3.4. Upravljačka petlja	33
6. Rezultati	40
6.1. Natjecanje RoboSoft 2025	40
6.2. Opis zadatka i demonstracije	41
6.3. Demonstracija na konferenciji hrvatskih robotičara	42
7. Zaključak	44
Literatura	45

1. Uvod

Podatna robotika dio je robotike usmjeren na izradu robota od prilagodljivih materijala s ciljem rukovanja osjetljivim predmetima ili tkivima. Eksperti ovog područja [1] smatraju da su alati napravljeni od materijala koji omogućuju savijanje, prijanjanje i vraćanje u izvorni oblik, vrlo pogodni za rješavanje problema s kojima se susreće podatna robotika. Zbog toga, u usporedbi s uobičajenim industrijskim robotima, podatni roboti više nalikuju mekim biološkim organizmima te su najčešće korišteni u područjima medicine, poljoprivrede, istraživanjima oceana i svemira te još mnogo raznih područja.

Ovi roboti pogonjeni su na različite načine – od pritiska zraka (pneumatski) ili tekućine (hidraulički) do toplinskih podražaja koji mijenjaju oblik robota [2]. Najčešće korišten način aktucije je pneumatski. Takvi aktuatori su skalabilni, cjenovno pristupačni, imaju brz radni ciklus i neosjetljivi su na temperaturna odstupanja. Ipak, pneumatski aktuatori zahtijevaju veliku dodatnu opremu koja se mora montirati kako bi mogli raditi, zbog čega smo se u našem radu odlučili za DC motor.

U sklopu ovog rada razvijen je autonomni podatni robotski sustav pod BerryBot namijenjen za branje malina. BerryBot je sposoban autonomno detektirati maline pomoću kamere te ih ubrati i odložiti u košaru. Kao podatni alat za branje korištena je postojeća hvataljka izrađena u laboratoriju LARICS (Laboratorij za inteligentne autonomne sustave), naziva SofIA [3]. U svrhu ovog projekta, prsti navedene hvataljke morali su biti prilagođeni za rukovanje sitnim plodovima maline, što je zahtijevalo njihovu doradu i ugradnju senzora.

Razvijeni sustav primijenjen je na natjecanju RoboSoft 2025 [4]. Nakon uspješ-

nog sudjelovanja na natjecanju bili smo pozvani demonstrirati funkcionalnost sustava na izložbenom prostoru tijekom trajanja CRC-a (*Croatian Robotics Conference*) u Čakovcu.

U idućem poglavlju 2 detaljnije je opisana teorijska osnova pojedinih dijelova sustava. To uključuje opis korištene kamere, senzora te robotske ruke. Nakon potrebne teorijske osnove, u 3 poglavlju opisana je izrada hvataljke, njene karakteristike i objašnjen je snimljeni odziv senzora ugrađenog u nju. 4 poglavlje opisuje detekciju malina, što obuhvaća izolaciju maline pomoću boje na slici te izračun orijentacije. Zatim, 5 poglavlje govori o sveobuhvatnoj implementaciji autonomnog robotskog sustava. 6 prikazuje rezultate sustava i u konačnici 7 dio je zaključak.

2. Teorijska osnova

Ovo poglavlje daje pregled glavnih komponenti koje su bile korištene u razvijenom sustavu, uz objašnjenje teorijskih temelja koji stoje iza njihove funkcionalnosti. To obuhvaća principe rada podatnih robotskih hvataljki, senzora savijanja, kamere te robotske ruke koja je bila korištena za ovaj projekt. Razumijevanje ovih koncepata bitno je za shvaćanje funkcionalnosti i odluka koje su bile donošene pri implementaciji robota.

2.1. Podatne hvataljke

Ovo brzorastuće područje robotike, *podatna robotika*, primarno se fokusira na unaprijeđenje načina na koji roboti rukuju predmetima [6]. Za razliku od tradicionalnih robota izrađenih od čvrstih materijala, kod mekih se robota koriste elastomeri i fleksibilni materijali što omogućuje prilagodljivost i sigurniju interakciju s osjetljivim objektima. Također, u nekim slučajevima ova karakteristika olakšava robotu kretanje u raznim složenim okruženjima poput cijevi ili skučenih prostora. Mnogo hvataljki inspirirano je biološkim sustavima poput pipaka hobotnica, crvi [7] ili ljudskih ruku. Na slici 2.1 prikazan je jedan od novijih primjeraka meke hvataljke. Prirodna fleksibilnost hvataljke olakšava implementaciju i smanjuje rizik od



Slika 2.1: Primjer meke hvataljke [5]

oštećenja predmeta prilikom rukovanja predmetima različitih oblika i veličina.

Robotski sustavi za rukovanje osjetljivim predmetima mogu se primijeniti u širokom i raznolikom spektru proizvodnih procesa [8]. Na primjer, korištenje robota za manipuliranje proizvodima u hortikulturnom sektoru moglo bi smanjiti troškove rada, povećati produktivnost i poboljšati uvjete rada [9]. Njihove karakteristike čine podatne robote idealnima za primjene u poljoprivredi (za berbu voća), medicini (za robotsku kirurgiju) i logistici (za rukovanje krhkom robom).

Preciznost hvataljke moguće je unaprijediti ugradnjom senzora unutar hvataljke te razvojem upravljačkih algoritama koji na pametan način koriste podatke iz okoline. U svrhu ovog projekta izrađeni su vlastiti podatni prsti koji su odgovarali problemu branja malina te je u njih ugrađen senzor savijanja kako bi se dobila povratna informacija o jačini stiska. O navedenim prstima i senzoru bit će više riječi u narednim poglavljima.

2.2. Senzor savijanja


Senzori savijanja (*flex sensor*) predstavljaju jednostavna, ali učinkovita rješenja za mjerenje stupnja savijenosti. Ovi senzori obično rade na principu promjene električnih svojstava, najčešće otpora, koji postaje proporcionalan stupnju savijanja. Zbog svoje fleksibilnosti i relativno niske cijene, nalaze široku primjenu u različitim područjima, od nosive elektronike do autonomnih robotskih sustava. U ovom konkretnom projektu, senzor savijanja je korišten za dobivanje povratne informacije o savijenosti meke robotske hvataljke. Upotrijebljen je *Bend Labs 1-axis* [10] kapacitivni senzor savijanja. On dolazi s ugrađenim modulom koji šalje podatke digitalno putem I²C sučelja, bez potrebe za dodatnim analognim sklopovima. Kao što naziv sugerira, ovaj senzor mjeri savijanje po jednoj osi, u negativnom i pozitivnom smjeru.

U ovom projektu, senzor savijanja omogućio je precizno praćenje stupnja savijenosti prstiju hvataljke, što je bilo ključno za ostvarivanje nježnog i kontroliranog hvatanja osjetljivih malina. Na slici 2.2 prikazan je korišteni senzor savijanja.



Slika 2.2: Korišteni senzor savijanja, Bend Labs 1-axis flex sensor

Na slici 2.3 prikazano je kako je senzor bio povezan s mikrokontrolerom Arduino UNO [11] kako bi se podaci očitavali s njega. Mikrokontroler serijski šalje podatke na računalo u koje je spojen te se podaci dalje obrađuju u algoritmu. O odzivu senzora bit će više riječi u idućem poglavlju.



Slika 2.3: Spajanje flex senzora

2.3. Dubinska kamera i kalibracija


Dubinske kamere, poput Intel RealSense D435 [12] koja je bila korištena u sklopu ovog projekta, omogućavaju percepciju okoline u tri dimenzije. Za razliku od standardnih RGB kamera koje bilježe samo boju i intenzitet svjetlosti, dubinske kamere mjere i udaljenost do točaka u vidnom polju. To se obično postiže projiciranjem infracrvenih uzoraka i analizom njihove deformacije. Rezultat je dubinska slika na kojoj svaki piksel sadrži i informaciju o udaljenosti do odgovarajuće točke u prostoru. Uz pomoć ove kamere moguće je napraviti i oblak točaka (*engl. pointcloud*) vidnog polja. Ukratko, to je 3D oblak točaka koji predstavlja prostorni raspored objekata u vidnom

polju kamere.



Slika 2.4: Intel Realsense D435


Da bi se osigurali precizni podaci slike i dubine, kameru je potrebno kalibrirati. To je proces određivanja unutarnjih (*engl. intrinsic*) parametara kamere (poput žarišne duljine, optičkog centra i distorzije leće) te vanjskih (*engl. extrinsic*) parametara (pozicija i orijentacija kamere u odnosu na neki referentni koordinatni sustav) [13]. Obje vrste kalibracije provode se pomoću nekog poznatog uzorka (npr. šahovnica) koji kamera prepoznaje (korištenjem kalibracijskog algoritma), međutim služe različitim svrhama. Unutarnjom kalibracijom kamere izračunavaju se parametri koji kasnije služe za projekciju trodimenzionalnih točaka iz prostora u dvodimenzionalnu sliku. S druge strane, vanjskom kalibracijom dobiva se položaj same kamere u prostoru u odnosu na neki referentni okvir. Na primjer, ako koristimo šahovnicu za kalibraciju [14], onda se dobije translacija i rotacija kamere u odnosu na zadnji zglobov u kinematičkom lancu robota pomoću koordinatnog sustava šahovnice. Neprecizna kalibracija može dovesti do značajnih pogrešaka i izobličenja pri mjerenju dubine, što bi negativno utjecalo na performanse robotskih zadataka poput detekcije i lociranja manjih objekata poput malina. Stoga se proces kalibracije provodi korištenjem poznatih uzoraka kako bi se kompenzirale nesavršenosti kamere i osigurala pouzdana percepcija stvarnosti. U svrhu kalibracije kamere u ovom sustavu bili su korišteni "ArUco" markeri sa slike 2.5 i *MoveIt!* ROS paket [15] za kalibraciju.



Slika 2.5: ArUco markeri

2.4. Robotska ruka i primjene

Robotska ruka je mehatronički sustav koji oponaša funkcionalnost ljudske ruke, sastavljen od zglobno povezanih segmenata (članaka) i aktuatora koji omogućuju pomicanje u više stupnjeva slobode. Robotske ruke već se desetljećima koriste u različitim granama industrije, prvenstveno za zadatke automatizacije koji zahtijevaju preciznost, ponovljivost i brzinu. Njihova osnovna funkcija je manipulacija objektima u neposrednoj blizini, čime efikasno oponašaju ljudsku ruku u zadacima poput sastavljanja, varenja, pakiranja ili sortiranja. S vremenom su postale sve robusnije – ne samo u mehaničkom smislu, već i u pogledu upravljačkog softvera i sposobnosti prilagodbe različitim uvjetima rada, poput kolaborativnih robota koji su opremljeni senzorima kojima je cilj sigurna suradnja s ljudima. Tradicionalne robotske ruke često se koriste u strogo kontroliranim okruženjima, gdje im je snaga i preciznost ključna prednost, ali s razvojem meke robotike otvara se prostor za još sofisticiranije pristupe rukovanju objektima, osobito onima osjetljivim i nepravilnih oblika.



Slika 2.6: Primjer robotske ruke

Među poznatijim robotima koji su korišteni za ovakve aplikacije su Kinova [16], Universal Robots (UR) [17], Franka Emika Panda [18] i ostali. Sveučilišna bolnica u Kopenhagenu u Gentofteu u Danskoj istražila je koliko su kolaborativni roboti isplativo rješenje za automatizaciju ručnog sortiranja uzoraka krvi [19]. Robotski uređaj morao se smjestiti u područje laboratorija s ograničenim prostorom gdje veći, automatizirani utovarivači rasutih uzoraka nisu bili opcija. Bolnički laboratorij želio je da tehničari mogu komunicirati s robotom i lako intervenirati ako proces rukovanja zahtijeva ljudsku intervenciju. Suočena s 20%-tnim povećanjem količine uzoraka krvi koji stižu u laboratorij, uprava je također nastojala održati cilj laboratorija da se 90% svih uzoraka krvi analizira unutar sat vremena bez potrebe za dodavanjem dodatnog osoblja. Dva UR5 robota sada optimiziraju rukovanje i sortiranje uzoraka krvi za analizu u sveučilišnoj bolnici u Gentofteu u Kopenhagenu. Rješenje omogućuje laboratoriju da održi cilj isporuke više od 90% rezultata unutar 1 sata unatoč 20%-tnom povećanju broja uzoraka koji dolaze na analizu.



Slika 2.7: Sortiranje uzoraka krvi pomoću UR robotske ruke [19]

Kada se u obzir uzme preciznost i pouzdanost koju kolaborativne robotske ruke već posjeduju te ih se dodatno nadogradi mekom hvataljkom i skupom senzora – poput taktilnih, vizualnih i silomjernih – dobije se sustav sposoban za osjetljivu i prilagodljivu manipulaciju. Na taj način, robotska ruka ne samo da proširuje funkcionalnost postojećih robotskih platformi, već otvara vrata potpuno novim primjenama. Takvi hibridni sustavi mogu, primjerice, precizno rukovati laboratorijskim uzorcima, asistirati u kirurgiji pa i nježno brati zrelo voće. U konačnici, njihova primjena postaje ograničena jedino našom kreativnošću.

2.5. Robotski operacijski sustav

Robot Operating System (ROS) [20] predstavlja fleksibilan i moćan okvir za razvoj softverskih rješenja u području robotike. Unatoč nazivu, ROS nije operacijski sustav u uobičajenom smislu riječi, već skup alata i biblioteka koji omogućuju izgradnju modularnih i distribuiranih robotskih sustava. Pruža ključne funkcionalnosti poput apstrakcije hardvera, upravljanja uređajima niže razine, obrade podataka sa senzora, komunikacije između procesa te upravljanja paketima i ovisnostima.

Zahvaljujući arhitekturi temeljenoj na neovisnim komponentama, tzv. čvorovima, ROS omogućuje jednostavno razdvajanje složenih zadataka na manje dijelove koji mogu neovisno funkcionirati i međusobno komunicirati. Komunikacija se ostvaruje putem različitih mehanizama – tema, servisa, akcija i parametara – što omogućuje

fleksibilnu i skalabilnu izgradnju sustava. Ovakav pristup znatno olakšava razvoj, testiranje i održavanje robota.

ROS podržava više programskih jezika, pri čemu se u praksi najviše koriste Python i C++. Python omogućuje brzu implementaciju i često se koristi za obradu senzorskih podataka i vizualizaciju, dok C++ osigurava veću učinkovitost i koristi se u vremenski kritičnim dijelovima sustava, primjerice za upravljanje aktuatorima i komunikaciju sa sučeljima.

Zahvaljujući širokoj zajednici korisnika i razvijatelja, ROS ekosustav obiluje otvorenim softverskim rješenjima, što značajno ubrzava razvoj i smanjuje troškove. Upravo zbog svoje modularnosti, podrške za veliki broj senzora i aktuatora te jednostavne integracije složenih funkcionalnosti poput navigacije, kinematike i obrade slike, ROS je postao neizostavan alat u modernoj robotici – od akademskih istraživanja do industrijskih primjena.

3. Izrada hvataljke

U ovom poglavlju detaljno će biti opisan proces izrade hvataljke. Prije svega, potrebno je utvrditi koje karakteristike hvataljka mora imati, a zatim donijeti odluke o odabiru materijala i načinu izrade. Za potrebe ovog projekta korištena je postojeća hvataljka *SofIA* [3], razvijena u laboratoriju za inteligentne i autonomne sustave (LA-RICS). SofIa se, zbog svog dizajna zasnovanog na *Fin-Ray* efektu, pokazala idealnom za rukovanje osjetljivim objektima. U ovom projektu prsti hvataljke bili su prenamijenjeni za branje malina.

3.1. Zahtjevi za hvataljku

U kontekstu robotike za berbu voća i povrća, izazovi su brojni i složeni. Tradicionalne, krute robotske hvataljke često su neprikladne zbog rizika od oštećenja osjetljivih plodova, ali i zbog varijabilnosti u veličini, obliku i stupnju zrelosti plodova. Stoga se u ovakvim primjenama sve češće koristi podatna robotika. Mekane hvataljke, izrađene od fleksibilnih materijala poput silikona ili elastomera, dizajnirane su tako da se prilagođavaju nepravilnim oblicima i ravnomjerno distribuiraju silu hvatanja na većoj površini, čime se smanjuje pritisak na osjetljive dijelove.

Dizajn meke hvataljke vođen je njenim funkcionalnim zahtjevima. Primarni zadatak hvataljke jest precizno i nježno branje iznimno mekih i osjetljivih plodova bez nanošenja oštećenja. Uzimajući navedeno u obzir, ključni zahtjevi bili su usmjereni na minimizaciju sile pritiska te maksimiziranje prilagodljivosti obliku ploda.

Specifični zahtjevi za ovu hvataljku uključivali su:

Nježnu interakciju: hvataljka mora biti sposobna uhvatiti i zadržati malinu s minimalnom silom pritiska koja neće uzrokovati gnječenje ili oštećenje vanjske strukture ploda.

Prilagodljivost obliku: prsti hvataljke moraju se optimalno prilagoditi nepravilnim i varijabilnim oblicima malina, osiguravajući stabilan hvat bez obzira na orijentaciju ploda.

Optimalna sila hvatanja: Potrebno je osigurati preciznu kontrolu sile hvatanja, dovoljno jaku da se plod odvoji od peteljke, ali istovremeno iznimno nježnu kako bi se izbjeglo oštećenje.

Robusnost i trajnost: unatoč svojoj "mekoj" prirodi, hvataljka mora biti dovoljno robusna da izdrži ponavljajuće cikluse branja u potencijalno vlažnom ili prašnjavom okruženju.


Mogućnost integracije senzora: potrebna je mogućnost jednostavne integracije senzora savijanja ili taktilnih senzora za pružanje povratne informacije o položaju prstiju i detekciji kontakta s plodom.

Postavljanje ovih zahtjeva bilo je ključno za usmjeravanje cijelog procesa dizajna, odabira materijala i metoda izrade.

3.2. Model hvataljke

Za postojeću hvataljku SofIA izrađeni su novi, mekši prsti s ugrađenim kosturom i senzorom, dok su njeni ostali tvrdi dijelovi konstrukcije i pogonskog sustava ostali nepromijenjeni.


Prijašnji model, koji je moguće vidjeti na slici 3.1 (preuzet iz članka dostupnog na poveznici [3]), je problem savijanja prstiju prema dolje rješavao pomoću ugradnje šarki duž prsta. U novom modelu, šarke su zamijenjene savitljivim plastičnim kosturom unutar prstiju. Također, u svrhu dobivanja povratne informacije o sili savijanja hvataljke, ugrađen je i senzor savijanja unutar novih prsti.



Slika 3.1: Postojeći model hvataljke SofIA, prije nadogradnje

Za potrebe vizualizacije kod izrade kalupa za nove prste odabran je program Blender. To je besplatan *open source* grafički softver. Blender je iznimno moćan alat koji nudi širok spektar funkcionalnosti, od modeliranja i oblikovanja do renderinga i animacije, što ga čini idealnim za robotske sustave kod kojih je vizualizacija ključna.

Na slici 3.2 prikazan je uvezeni model SofIA hvataljke.



Slika 3.2: Postojeći 3D model hvataljke


3.3. Prenamjena hvataljke

Postojećoj hvataljci bilo je potrebno promijeniti prste. Ostatak konstrukcije i mehanizma pokretanja nije bio mijenjan. Novi prsti trebali su biti od vrlo mekog materijala te je u tu svrhu odabran dvokomponentni silikon.



Slika 3.3: Dvokomponentni silikon

Dakle, dijelovi hvataljke koji po svojstvima nisu trebali biti meki i prilagodljivi izrađeni su od PLA (*polilaktična kiselina*) filamenta. PLA filament poznat je po svojem biorazgradivom svojstvu i iznimno jednostavnom procesu proizvodnje. Neki od čvrstih dijelova hvataljke izrađeni od PLA su: prihvatna konstrukcija (dio koji služi za montiranje hvataljke na robotsku ruku), stalak za kameru, savitljive kosti unutar silikonskih prstiju, mehanizam za pretvorbu rotacijskog gibanja motora u translacijski pokret te postolje za motor.




Slika 3.4: SofIA s novim prstima


Glavni dio ovog izazova, mekani prsti hvataljke, napravljeni su od dvokomponentnog silikona. Ovisno o vrsti silikona bitno je pridržavati se propisanih omjera kod vaganja baze i katalizatora. U suprotnom, moguće je da se smjesa neće osušiti ili imati očekivana svojstva. Silikon sa slike 3.3, koji je bio korišten za ove potrebe, miješa se u omjeru 1:1 te njegovo skrućivanje traje 4 sata. U prethodno 3D isprintani kalup 3.5 uljeven je silikon koji je nakon par sati poprimio oblik sa slike 3.4.

Prije ulijevanja samog silikona, u kalup je umetnut crni plastični kostur koji je moguće vidjeti na slici 3.6. Naime, ovaj plastični kostur ključan je element konstrukcije jer omogućuje otpornost na vertikalno savijanje prstiju, a pritom zadržava njihovu fleksibilnost u horizontalnom smjeru. Uz kostur je također dodan i ranije spomenuti senzor savijanja, preko kojeg je izliven silikon.

Nakon što su prsti montirani na hvataljku, u korijenu između prstiju dodana je i crna vezica koju je moguće vidjeti na slici 3.4, koja ih spaja u jednoj točki. Ovaj dodatak posve mijenja kinematiku i način hvatanja hvataljke. Kada vezica ne bi postojala, prsti bi se zatvorili na način da se svinu prema van te bi se time formirala rupa s unutarnje strane između prstiju. Ovo ponašanje ne bi bilo idealno jer tada ne bi postojao pritisak na malinu te bi ona ispala iz hvataljke. Da bismo izbjegli takvo ponašanje prstiju, dodana je vezica koja omogućuje željeno otvaranje i zatvaranje hvataljke.



Slika 3.5: Isprintani kalupi za prste




Slika 3.6: Kostur

3.4. Karakterizacija hvataljke

Po završetku konstrukcije hvataljke, proveden je niz testiranja s ciljem evaluacije njezine funkcionalnosti. Bilo je potrebno prilagoditi hvataljku uvjetima stvarne berbe i veličini malina koje će se brati. Korišten je Dynamixel XM-430 [21] motor koji otvara i zatvara hvataljku te su određene maksimalna i minimalna pozicija (otvoreno i zatvoreno) koje hvataljka može izvesti. Ove pozicije vrlo su bitne jer se koriste za ograničenje motora. Naime, nakon fizičke realizacije bilo kakvog sustava, potrebno je odrediti njegova prostorna ograničenja i mogućnosti kako ne bi došlo do neželjenih kolizija ili oštećenja. U ovom slučaju, ako se motor ne ograniči, moguće je da napravi cijeli krug te plastično vratilo (koje prenosi to gibanje) pukne. Zbog toga su na početku iščitane navedene vrijednosti te je rotacija motora ograničena u algoritmu.


Precizna kontrola stiska ključna je pri rukovanju malinama, a ostvaruje se pomoću senzora savijanja integriranog u hvataljku, što je spomenuto u prethodnom poglavlju. Testiranjem stisaka maline i snimanjem odziva tog senzora određena je jačina optimalnog stiska maline. Bitno je da je dovoljno jako stisnuta između prstiju da ju je moguće otkinuti sa peteljke, ali u isto vrijeme stisak mora biti dovoljno slab da se ne zgnječi.

Više puta je proveden eksperiment te su snimljeni odzivi senzora. Na slici 3.7 bitno je primijetiti da senzor daje odzive koji naizgled titraju oko točne vrijednosti za 6° . Zbog toga je potrebno uzeti srednju vrijednost nakon što se položaj senzora stabilizira. Na taj način ustanovljeno je da je senzor pri otvorenoj hvataljci savijen za -66° , što je 0.5 sekundi od početka snimanja odziva, a s uhvaćenom malinom -57° . Ove vrijednosti moguće je iščitati sa slike 3.7.



Slika 3.7: Odziv flex senzora

Slika 3.8 prikazuje korespondentne poze hvataljke čiji odzivi su prikazani na grafu 3.7. Dakle, Na slici s lijeve strane je prikazana otvorena hvataljka, ona se zatvara (što je vidljivo i u postepenoj promijeni savijenosti senzora) te hvata malinu.




Slika 3.8: Mjerenje savijenosti senzora pri otvorenoj i zatvorenoj hvataljci

4. Detekcija malina na slici

Budući da je boja jedan od najjasnijih pokazatelja zrelosti malina, odabrana je metoda detekcije temeljena na prepoznavanju boje u slikama dobivenim s kamere. Naime, na početku branja fotografiraju se svi dijelovi grmlja koje robot može doseći. Nakon toga odrađuje se detekcija, a zatim postupak branja.

4.1. Izolacija pomoću boje

Detekcija je implementirana korištenjem knjižnice OpenCV, poznate po alatima za obradu slike i računalni vid. Za izolaciju boje korišten je HSV (Hue, Saturation, Value) prostor, jer bolje odvaja nijanse od intenziteta svjetlosti u odnosu na RGB. Na temelju unaprijed definiranih raspona HSV vrijednosti za ciljanu boju (u ovom slučaju rozu), primijenjena je binarna maska pomoću funkcije `cv2.inRange()`. Na slici 4.1 moguće je vidjeti rezultat ove operacije.



Slika 4.1: Segmentacija maline po boji. Zelena točka prikazuje centroid maline, a broj je udaljenost od te točke do centra kamere. S desne strane je maska maline.

U slici su istaknuti samo pikseli koji pripadaju željenom rasponu boje, dok su ostali

uklonjeni. Dobivena maska može se dalje koristiti za izdvajanje objekata ili analizu kontura.

Nakon ispravne detekcije ploda maline po boji, bilo je potrebno odrediti njegovu poziciju u odnosu na kameru. Koristeći ranije spomenute unutarnje parametre kamere, dobivena je prostorna pozicija maline u odnosu na kameru. Unutarnji parametri kamere opisuju unutarnje karakteristike kamere, odnosno kako ona pretvara 3D točke iz svog koordinatnog sustava u 2D točke na slici (piksele). Oni se nalaze u tzv. intrinzičnoj matrici K i uključuju žarišnu duljinu u vodoravnom (f_x) i okomitom (f_y) smjeru te koordinate optičkog centra slike (c_x , c_y). Matricu K moguće je u svakom trenutku dohvatiti kada je kamera spojena na računalo.

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}$$

Slika 4.2: Intrinzični parametri kamere

Ovi podaci bitni su kada želimo izračunati stvarnu prostornu poziciju neke točke iz slike. Dakle, moramo vratiti informaciju iz slike nazad u prostor. Intrinzični parametri govore nam koliku veličinu jedan piksel predstavlja u stvarnom prostoru, gdje se nalazi optički centar slike i kako skalirati položaj točke iz slike u stvarnu udaljenost. Stoga formula koja je bila korištena za izračun koordinata maline izgleda ovako:

$$X = \frac{(u - c_x) \cdot Z}{f_x}, \quad Y = \frac{(v - c_y) \cdot Z}{f_y}, \quad (u,v) = \text{piksel sa slike}$$

$$Z = \text{dubina u točki } (u, v)$$

Programsku implementaciju pretvorbe piksela sa slike u prostorne koordinate kamere moguće je vidjeti u samom algoritmu [22] u implementaciji čvora *exteroception.py* u funkciji *get_3d_coordinates_from_depth()*.

Nakon dobivenih prostornih koordinata detektirane maline, slijedi njihova pretvorba u bazu robota. Naime, kako bi robot uspješno mogao doći do željene točke

u prostoru (u ovom slučaju vrh hvataljke do maline) potrebno je koordinate koje daje kamera transformirati u bazu samog robota. Kako bi se to ostvarilo, bitno je da je kamera ispravno kalibrirana te da je ona dio kinematičkog lanca robotske ruke. Kamera je prethodno kalibrirana te su sve transformacije od optičkog koordinatnog sustava kamere pa sve do baze robotske ruke poznate. Ostaje samo iskoristiti te transformacije kako bi se dobivene koordinate maline transformirale u koordinate baze robota. Ove operacije također je moguće vidjeti u implementaciji na poveznici [22]. Ondje se koristi ROS paket *tf* [23] koji sprema transformacije u određenom trenutku te ih je moguće dohvatiti i koristiti za pretvorbu.

4.2. Optimiranje poze hvatanja

S obzirom na različite položaje i orijentacije malina u prostoru, bilo je potrebno razviti metodu kojom se može procijeniti njihov zakret. Testiranjem je ustanovljeno da nije dovoljno prilaziti hvataljkom vodoravno na malinu jer tako malina može skliznuti iz hvata ili ju pak uopće nije moguće uhvatiti. U svrhu izračuna zakreta maline korišteni su momenti kontura maline sa slike. Zakret se računa pomoću centralnih momenata drugog reda prema sljedećoj formuli:


$$\theta = \frac{1}{2} \arctan \left(\frac{2\mu_{11}}{\mu_{20} - \mu_{02}} \right). \quad (4.1)$$

Ovdje je θ kut zakreta glavne osi inercije objekta izražen u radijanima. Centralni momenti μ_{pq} predstavljaju raspodjelu mase objekta (konture) oko njegovog težišta. U ovoj formuli koriste se:

- μ_{20} – drugi centralni moment u odnosu na x-os koji mjeri raspršenje piksela u horizontalnom smjeru,
- μ_{02} – drugi centralni moment u odnosu na y-os koji mjeri raspršenje piksela u vertikalnom smjeru,

- μ_{11} – miješani centralni moment koji opisuje međusobnu korelaciju između x i y koordinata.

Centralni momenti dobiveni su pomoću funkcije iz OpenCV knjižnice `cv2.moments()` te su korišteni u gore navedenoj formuli za izračun zakreta. Ova formula zapravo daje orijentaciju elipse koja najbolje aproksimira oblik maske objekta, u ovom slučaju maline. Dobiveni zakret omogućio je poravnatu orijentaciju hvataljke robota s položajem ploda. Na slici 4.3 vidljiv je prikaz linije koja predstavlja izračunati kut nagiba maline.



Slika 4.3: Izračun kuta zakreta maline


Programski je omogućeno da se u stvarnom vremenu prikazuje zakret maline te robot sukladno tome planira svoje kretanje i poravna se sa malinom. U nadolazećim poglavljima bit će opisano kako je kontrola robota implementirana te kako robot planira svoje kretanje.

5. Autonomni robotski sustav:

BerryBot

Primjena robota u poljoprivredi na velikim farmama nije novost, već dio industrije koja bilježi stalan rast, s naglaskom na automatizaciju teških mehaniziranih procesa prilagođenih određenim kulturama i specifičnim zadacima. Ipak, u slučaju osjetljivih biljaka koje se ne sade iznova svake godine te proizvode lako oštećive plodove, nameće se potreba za osmišljenijim pristupom koji omogućuje precizno djelovanje bez narušavanja integriteta biljke ili ploda. Jedan od glavnih izazova jest postići visoku razinu preciznosti te oblikovati manipulator koji će se moći prilagoditi plodu, omogućujući manipulaciju uz što manju mogućnost oštećenja biljke. Takav pristup temelji se na načelima podatne robotike, čija se istraživanja usmjeravaju prema razvoju sofisticiranih senzorskih i aktuatorskih sustava, sposobnih za precizno upravljanje koje u određenim aspektima imitira ljudsku motoriku. Ispitivanje robota u tako osjetljivim uvjetima predstavlja značajnu istraživačku priliku, koja može doprinijeti razvoju novih rješenja i dubljem razumijevanju izazova u ovom dinamičnom i sve važnijem području [24].

Autonomni robotski sustav "BerryBot" ima mogućnost: detektirati, ubrati i odložiti maline u košaru. Sustav se sastoji od UR5 robota na kojem je montirana hvataljka SofIA [3] te pomoćni dodatak od 90 stupnjeva koji povećava spretnost (engl. *dexterity*) robota (Slika 5.1).



Slika 5.1: Izgled BerryBot-a i dijelovi

Na Slici 5.2 vide se komponente SofIA hvataljke te kako su oni montirani.




Slika 5.2: Hvataljka i njeni dijelovi

5.1. Simulacijsko okruženje

Izrada robotskih sustava vrlo je skupa, pogotovo u testnim fazama u kojima ponašanje robota nije uvijek predvidivo. Zbog toga se prije fizičke izvedbe bilo kakvog robotskog ili automatiziranog sustava najprije izrađuju simulacije. Jedan od takvih

okruženja je i Gazebo, program otvorenog koda koji nudi simulacijsko okruženje za razvoj i testiranje robotskih sustava. Prvobitno razvijen od strane Open Source Robotics Foundation (sada Open Robotics), Gazebo je usko integriran s robotskim operativnim sustavom (ROS), čime osigurava besprijekorne prijelaze između simulacije i implementacije u stvarnom svijetu. Njegova modularnost te podrška za višestruke fizičke motore omogućuje istraživačima da prilagode simulacije svojim specifičnim zahtjevima. Zbog svoje fleksibilnosti i snažne podrške zajednice, Gazebo je postao standardna platforma za simulaciju u akademskim i industrijskim istraživanjima robotike [25]. Kad se pokrene simulacijski prostor za testiranje, Gazebo izgleda kao na slici 5.3



Slika 5.3: Gazebo simulacija s UR robotskom rukom

5.1.1. Konfiguracija simulacijskog modela robota


Datoteka koja opisuje robotsku ruku i njene parametre nalazi se unutar podijeljenih datoteka preuzetih s github stranice UR-a [26]. Nakon uvoza navedene datoteke, nju je moguće nadograđivati vlastitim opisima konfiguracije robota. Simulacijski prostor ne služi samo da bi se vizualizirali pokreti robota u okolini, već ima i veliku ulogu u planiranju putanja i trajektorija robota.

Svaka robotska ruka ima određeni stupanj spretnosti, odnosno ograničenja u pogledu gibanja unutar radnog prostora. Prije početka rada razmatrane su dvije mo-

guće konfiguracije: izravna montaža hvataljke na kraj robotske ruke ili ugradnja 90-stupanjskog profila između ruke i hvataljke.

Nakon provedenih testiranja pokazalo se da robotska ruka UR5, odabrana za rad u ovom projektu, pokazuje veću razinu spretnosti kada je opremljena profilom pod kutom od 90 stupnjeva (Slika 5.1), omogućujući dohvat znatno većeg broja pozicija u svom radnom prostoru. Naime, testirani sustav bez dodatka od 90 stupnjeva nije mogao pokriti pojedine točke s lijeve strane ploče na kojoj su bile maline. To je bilo ograničenje same konfiguracije zglobova robota i prostora koji on može pokriti. Stoga je dodavanjem zakreta od 90 stupnjeva olakšano i optimirano kretanje unutar okvira ploče koja je bila korištena.

Uz navedeno, u simulacijski je prostor dodan i model hvataljke kako bi postao sastavni dio okruženja i bio uzet u obzir kod planiranja putanja. Pokretanjem simulacije prikazuje se scena poput one na slici 5.4.



Slika 5.4: Konačna konfiguracija robota


5.2. Stvarno okruženje

Testiranje razvijenog robotskog sustava zahtijevalo je stabilan eksperimentalni postav. Bilo je pogodno da se plodovi malina mogu više puta iskoristiti za branje, ali da ih je uz to moguće i lako pomaknuti na drugo mjesto.

5.2.1. Izrada i testiranje sustava

S obzirom na to da se prave maline u prirodnim uvjetima vrlo lako oštete i kvare, pogodnije su umjetne maline koje su što sličnije pravima. Njih je također moguće iskoristiti u više eksperimenata. Osim umjetnih malina, izrađen je i postav koji imitira prirodnu okolinu u kojoj maline rastu.

Za izradu malina korišten je negativ oblika maline napravljen pomoću tvrdog silikona i 3D printane maline, što je prikazano na slici 5.5. U silikonski kalup ulijeven je mekši silikon koji najbolje imitira karakteristike prave maline.



Slika 5.5: Kalup za umjetne maline

Na slici 5.6 moguće je vidjeti hvataljku koja se približava umjetnoj malini na postavu. Malina je naknadno bila obojana crvenom bojom kako bi se gore opisana detekcija mogla provesti.



Slika 5.6: Branje maline

Izrađen je i postav koji imitira prave uvjete okoline. Na slici 5.7 prikazana je ploča s umjetnim lišćem i malinama na kojoj je testiran rad robota. Uz različite pozicije i broj malina sustav je testiran više puta te je ustanovljeno da se generalno ubere 8/10 zadanih malina. Ovaj broj moguće je povećati daljnjom nadogradnjom sustava; poboljšanjem kontrole i detekcije.



Slika 5.7: Postav za testiranje


5.3. Upravljanje robotskim sustavom

Kao što je prethodno navedeno, glavna softverska podloga ovog projekta je ROS, koji omogućuje programiranje robotskih akcija, obradu senzorskih podataka za upravljanje te, u konačnici, realizaciju zadatka branja malina.

ROS funkcionira na specifičan način koji omogućava stvaranje čvorova. Čvor je proces koji može izvoditi računanje, slati podatke, čitati podatke itd. Čvorovi se povezuju u mrežu i međusobno komuniciraju putem poruka kroz tzv. 'topic', 'service' i putem parametara unutar ROS sustava.

Čvorovi su dizajnirani za rad s pojedinim komponentama sustava, što znači da upravljanje robotom u pravilu uključuje više čvorova. Primjerice, jedan čvor upravlja laserskim daljinomjerom, drugi motorima robota, treći je zadužen za planiranje putanje, dok jedan služi za grafički prikaz sustava i njegovih stanja. Korištenje čvorova u ROS-u donosi brojne prednosti. Povećana je tolerancija na greške jer su rušenja ograničena na pojedinačne čvorove. Složenost koda manja je u usporedbi s monolitnim sustavima. Također, detalji implementacije dobro su skriveni jer čvorovi izlažu minimalni API ostatku grafa, što omogućuje laku zamjenu alternativnim implementacijama, čak i u drugim programskim jezicima.

Sustav pri samom pokretanju automatski stvara nekoliko čvorova koji omogućuju osnovnu stabilnost. Za potpunu kontrolu implementirana je i mogućnost ljudske intervencije te definirani čvorovi: *Proprioception*, *Exteroception*, *ur5_control* i *ur5_controller* a njihova je međusobna komunikacija prikazana na slici 5.8.



Slika 5.8: Blok dijagram programske arhitekture

5.3.1. Propriocepcija

Proprioception je čvor koji obrađuje podatke dobivene putem senzora savijanja smještenog unutar prsta hvataljke kako je ranije spomenuto. Podaci sa senzora služe za dobivanje informacija o tome koliko su prsti hvataljke savijeni tijekom hvatanja, čime se određuje trenutak kada je potrebno zaustaviti zatvaranje. Ponekad se dogodi da robot ne uhvati ništa – u tom slučaju podatak da se prsti nisu savili također je vrlo koristan, jer ukazuje na potrebu za ponavljanjem radnje. Ovaj čvor također nudi *ROS servis* koji kao povratnu informaciju daje *true* ako je malina uhvaćena ili *false* ako nije.

5.3.2. Eksterocepcija

Implementiran je i čvor *Exteroception*, koji upravlja radom kamere te obrađuje podatke dobivene s kamere. Kao što je prije navedeno, korištena je Intel RealSense D435 dubinska kamera, koja uz sliku daje i informaciju o dubini. Ovaj čvor ima zadatak

da, po potrebi, snimi sliku i dubinu, a zatim izvrši detekciju malina. Ako su maline prisutne, određuje njihovu prostornu poziciju.

Nakon uspješne detekcije i lociranja, zadatak čvora je izraditi redoslijed berbe. Plan sadrži informacije o svim detektiranim malinama u prostoru, pri čemu čvor pohranjuje njihove pozicije u memoriju. Maline se beru prema redoslijedu detekcije, odnosno prva detektirana malina prva se i bere. Čvor po potrebi prosljeđuje sustavu informacije o pojedinačnim malinama.


5.3.3. Upravljanje manipulatorom

Čvor *ur5_control* implementiran je za upravljanje robotskim manipulatorom. Korištenjem *MoveIt!*-a ostvaruje se planiranje gibanja, dok se većina funkcionalnosti oslanjanja na ROS servise koji se pozivaju za izvođenje pojedinih dijelova koda. Čvor omogućuje upravljanje rukom u kartezijskom i zglobnom prostoru, kontrolu hvataljke te dinamičku promjenu brzine kretanja.

Planiranje korištenjem *MoveIt!*-a


MoveIt! [27] je jedan od najraširenijih softverskih okvira (*frameworks*) za planiranje pokreta i upravljanje robotskim manipulatorima, razvijen prvenstveno za rad u okviru ROS sustava. Osmišljen je kako bi olakšao kompleksne zadatke kinematike, planiranja putanje, upravljanja sudarima i kontrole pokreta u realnom vremenu.

MoveIt! preko konfiguracija koristi opisani radni prostor i trenutno stanje zglobova robotske ruke za planiranje gibanja. Opis radnog prostora uključuje samo robotsku ruku, bez definirane podloge, što znači da *MoveIt!* interpretira prostor ispod robota kao slobodan za gibanje. Budući da je u ovom slučaju robotska ruka statična i nalazi se na podu, dodan je i element "pod" (Slika 5.9) koji se nalazi ispod robota kako bi *MoveIt!* prepoznao taj prostor kao prepreku. Time se ograničava gibanje prema dolje i sprječava kolizija ruke s podom. Na taj se način eliminiraju planirane poze koje bi dovele do gibanja ispod najniže točke robota.



Slika 5.9: Dodan pod unutar prostora robota

Osim poda, u prostoru se nalazi i "zid" postavljen ispred robota (Slika 5.10), koji služi kao imitacija ploče na koju se nalaze grane s malinama. Njegova uloga je ograničiti gibanje prema naprijed kako ne bi došlo do kolizije s pločom i granama.



Slika 5.10: Dodan zid unutar prostora robota

Upravljanje hvataljkom

Za kontrolu hvataljke potrebno je uspostaviti komunikaciju s čvorom njenog motora koji omogućuje otvaranje i zatvaranje. Potrebne informacije uključuju identifikacijski broj motora, vrijednost pozicije (otvorenost/zatvorenost) te naziv parametra. Slanjem takve naredbe ostvaruje se upravljanje hvataljkom koja se, ovisno o zadanoj poziciji, zatvara ili otvara.

Upravljanje robotom inverznom kinematikom

U robotici, inverzna kinematika koristi kinematičke jednadžbe [28] kako bi se izračunali parametri zglobova potrebni za postizanje željene konfiguracije (pozicije) alata, u ovom slučaju hvataljke.

U implementaciji ovog sustava, pomoću *MoveIt!*-a daje se naredba kontrolerima koji upravljaju robotom o tome gdje i kako se treba pomaknuti. *MoveIt!* ima ugrađenu logiku za planiranje i izvršavanje gibanja do ciljne poze uzimajući u obzir potencijalne kolizije.

Sekvenca izvođenja funkcionira na sljedeći način: najprije se brišu svi prethodni ciljevi, postavljaju se faktori skaliranja za brzinu i ubrzanje, trenutno stanje robota se koristi kao početna točka, a zatim se poziva funkcija za planiranje putanje. Ako planiranje uspije, putanja se izvršava i rezultat se označava kao uspješan. U suprotnom, ispisuje se greška i rezultat se označava kao neuspješan. Ova funkcionalnost je sinkrona, što znači da se tijekom izvođenja putanje onemogućava izvođenje drugih funkcija, poput upravljanja hvataljkom.

Upravljanje robotom direktnom kinematikom

Postupak planiranja i izvođenja kod direktne kinematike sličan je onome kod inverzne, s tom razlikom što su u ovom slučaju unaprijed poznati zakreti zglobova. Umjesto da *MoveIt!* računa potrebne zglobne konfiguracije, ciljna konfiguracija zadaje se izravno. Ova metoda pokazuje veću matematičku robusnost, stabilnost i pouzdanost u odnosu na inverznu kinematiku.

Direktna kinematika najčešće se koristi za dovođenje robota u konfiguraciju koja bi olakšala planiranje preciznijih putanja. Na primjer, ako se malina nalazi na lijevoj strani u odnosu na bazu robota, robot se prvo postavlja u odgovarajuću početnu konfiguraciju pomoću direktne kinematike, kako bi se zatim lakše i sigurnije planiralo gibanje inverznom kinematikom.

5.3.4. Upravljačka petlja

Ovo potpoglavlje opisuje implementaciju ROS čvora `ur5_controller`, koji služi kao "mozak" robota UR5. Čvor učestalo komunicira s drugim čvorovima kako bi prikupio potrebne informacije i donio odluke o sljedećim koracima u radu robota.

Čovjek u petlji

Okolina u kojoj se robot nalazi, kao i položaji malina u grmlju, često su nepredvidivi i teško dostupni, što branje malina čini iznimno zahtjevnim zadatkom za autonomne robote. Gotovo svi komercijalni autonomni roboti (pogotovo oni koji samostalno rade detekciju objekata) imaju i dodanu opciju ručne kontrole. Kod autonomnog branja malina također je potrebno omogućiti neku vrstu ljudske intervencije ako stvari krenu u neželjenom smjeru. Ponekad se, na primjer, dogodi da kamera neuspješno detektira maline ili malina jednostavno nije uhvaćena vidnim poljem kamere. Zbog toga je u algoritmu razvijenom u svrhu ovog projekta po završetku svakog snimanja moguće odabrati i opciju za preuzimanje kontrole nad robotom, što podrazumijeva tele-operaciju pozicije hvataljke preko kontrolne palice. Na taj je način osigurano da se poveća uspješnost branja malina.



Slika 5.11: Figurativna slika upravljanja robotskim manipulatorom pomoću kontrolne palice

U tom kontekstu, koristio se mehanizam koji omogućuje interpretaciju korisničkih naredbi s upravljačke palice te njihovu trenutnu pretvorbu u gibanje robota. Sustav je konfiguriran tako da se jasno definira koji su ulazi i izlazi komunikacije, što znači; povezane su određene tipke na upravljačkoj palici s osima kretanja robota. Osim tehničkih postavki koje se odnose na samu kontrolu, u obzir je uzeta i sigurnost okoline, koja je spomenuta u prethodnom odlomku. Dakle, izbjegavanje kolizija i ograničenja robota.


Kako bi ručna kontrola robota bila respozivna i trenutna, potrebno je kontinuirano slati i primati podatke sa kontrolne palice. Za očitavanje i objavu podataka s kontrolne palice zadužen je zaseban ROS čvor. Njegove podatke čita drugi čvor zadužen za pretvaranje tih informacija u konkretne naredbe akcije, pri čemu također oblikuje komande za brzinu i smjer kretanja krajnjeg alata robota.

Za pokretanje čitavog opisanog sustava; autonomnog i ručnog dijela, koristi se skup unaprijed definiranih naredbi koje omogućuju sinkronizirano uključivanje svih potrebnih komponenti. To uključuje konfiguraciju robota, postavke upravljačkih mehanizama i parametre relevantne za precizno upravljanje u stvarnom vremenu. Ova vrsta automatizirane inicijalizacije zapisuje se u takozvanom *launchfile*-u te osigurava da se svi dijelovi sustava pokrenu u pravom redoslijedu.

Priprema za branje

Jedan od poznatih problema u poljoprivrednoj robotici je prisutnost lišća koje raste uz plodove i ometa njihovu detekciju. Kako bi se osigurala pouzdana detekcija svih plodova, uključujući i onih djelomično zaklonjenih lišćem, korišteno je šest unaprijed definiranih pozicija za snimanje prostora.

Ove pozicije su određene ručno, analizom slike iz kamere, kako bi se osiguralo da kamera pokrije cijeli prostor ispred sebe iz više različitih kuteva. Time se povećava vjerojatnost detekcije svih plodova u vidnom polju. Robot, koristeći direktnu kinematiku, izvršava planirane putanje prema odabranim pozicijama. Kada dosegne poziciju, aktivira se kamera koja snima prostor i pohranjuje informacije o pozicijama malina relativno prema bazi robota, koristeći senzor dubine za određivanje udaljenosti do objekata kao što je opisano u prethodnom poglavlju.




Slika 5.12: Prikaz kako kamera detektira maline u prostoru

Nakon završetka snimanja, robotska ruka se, koristeći direktnu kinematiku i poznate zglobne konfiguracije, vraća u unaprijed definiranu "početnu" poziciju, optimalnu za početak berbe. Paralelno s povratkom ruke, u pozadini se odvija proces planiranja: sustav obrađuje prikupljene informacije o detektiranim pozicijama plodova i određuje redoslijed kojim će ruka izvoditi berbu.

Opis kontrolne petlje i intervencije čovjeka

Nakon što je plan izrađen, započinje sekvenca branja i odlaganja malina u košaru. Ova sekvenca uključuje automatizirane korake koje izvodi robot, ali i ključne točke u kojima je potrebna potvrda ili intervencija korisnika zbog varijabilnosti stvarnih uvjeta. U nastavku je prikazan tijek procesa s označenim mjestima gdje se u petlju uključuje čovjek. Na sljedećoj slici 5.13 prikazan je rad sustava u obliku automata stanja, a ispod slike nalazi se detaljan opis.



Slika 5.13: Rad sustava prikazan kao automat stanja

1. **Početna pozicija** – Prije svakog pokušaja branja, robot se dovodi u unaprijed definiranu početnu poziciju koristeći direktnu kinematiku (Slika 5.14).



Slika 5.14: Početna pozicija robota - hvataljka u centru, okrenuta prema ploči

2. **Odabir sljedeće maline** – Odabire se sljedeća malina prema planiranom redoslijedu. U ovom trenu moguće je potvrditi tu predloženu malinu, odbaciti je (čime će doći na red iduća planirana) ili preuzeti ručnu kontrolu.
3. **Konfiguracijska poza robota** – Ovisno o strani ploče na kojoj se nalazi malina, ruka se pozicionira bliže malini pomoću direktne kinematike. Dakle, repositionira se tako da gleda na lijevu ili desnu stranu ploče.
4. **Pozicija pripreme** – Robot dolazi na 10 cm udaljenosti od maline 5.15, gdje se vrlo kratko zaustavlja. Ovaj korak potreban je radi preciznijeg kretanja, smanjujući rizik od neželjene interakcije s okolnim malinama i lišćem.



Slika 5.15: Pozicioniranje robota 10 cm od maline

5. **Otvaranje hvataljke** – Hvataljka se otvara i priprema za hvatanje maline.
6. **Pozicija branja** – Robot se precizno pomiče prema poziciji maline, definiranoj kamerom.
7. **Zatvaranje hvataljke** – Hvataljka se zatvara kako bi zahvatila malinu. Intervencija korisnika: potvrda je li berba bila uspješna; ako nije, vraćanje u korak 4 ili ručna kontrola.



Slika 5.16: Hvatanje maline i trenutak odluke čovjeka

8. **Pozicija uzimanja** – Malina se povlači suprotno od svoje orijentacije na peteljki kako bi se najlakše otkinula s nje 5.17.



Slika 5.17: Branje maline okomito prema dolje

9. **Povratak u konfiguracijsku pozu** – Robot se vraća u prethodnu konfiguraciju kako bi izbjegao sudare i pripremio se za sljedeći korak.

10. **Početna pozicija** – Robot se ponovno postavlja u početnu poziciju za prijelaz na odlaganje.
11. **Pozicija odlaganja** – Robot se pomiče do košarice.



Slika 5.18: Robot ostavlja malinu

12. **Odlaganje u košaricu** – Hvataljka se otvara i malina se ispušta u košaricu 5.18.
13. **Završna odluka** – (*Intervencija korisnika: nakon što se sve maline uberu, korisnik bira hoće li pokušati ubrati ne-detektirane maline ručno ili završiti program.*)

Upute za korištenje se nalaze ovdje [29]

6. Rezultati

U ovom poglavlju pokazani su rezultati sustava koji je bio opisan u ovom radu.

Samu demonstraciju rada robota moguće je pogledati na YouTube-u preko poveznice: <https://www.youtube.com/watch?v=2Dc3zTNON3Y>.

6.1. Natjecanje RoboSoft 2025

Izrađeni robotski sustav predstavili smo na ovogodišnjem međunarodnom natjecanju "RoboSoft 2025" u Lausanne (Švicarska), uz mentorstvo izv. prof. dr. sc. Matka Orsaga i uz pomoć asistentice mag. ing. el. techn. inf. Jelene Vuletić.




Slika 6.1: Robosoft 2025

Kao što naziv sugerira, fokus natjecanja bio je područje meke robotike, odnosno razvoju mekih i adaptabilnih robotskih sustava. Natjecanje je bilo strukturirano u tri

tematske kategorije: autonomno branje malina, precizno robotsko upravljanje te lokomocija kroz uske prolaze.

6.2. Opis zadatka i demonstracije

Zadatak kategorije bio je konceptualno jednostavan: robotska ruka UR5 trebala je autonomno obaviti branje umjetnih malina s predviđenog postava, čiji je izgled prikazan na Slici 6.2. Ključni elementi postava bili su: umjetne maline, strukture koje imitiraju lišće i grane te mehanizam za simulaciju prirodnih uvjeta (vjetar).




(a) Tehnički crtež natjecateljskog postava (pogled srijeda)

(b) 3D vizualizacija natjecateljskog postava

Slika 6.2: Tehnička i vizualna dokumentacija natjecateljskog postava

Na samom natjecanju dobili smo operativni postav (Slika 6.3) i ograničen vremenski okvir od 10 minuta za pripremu i demonstraciju funkcionalnosti. Organizatori su postav opremili s umjetnim malinama i lišćem, te posebnim mehanizmom koji je pomoću motora simulirao gibanje biljaka pod utjecajem vjetra, što je stavilo natjecateljske robote u vrlo realne uvjete.



Slika 6.3: Stvarni izgled postava tijekom natjecanja

Iako je uspješno implementiran algoritam za detekciju i branje malina, bili smo plasirani na 5. poziciji. Fokus našeg sustava bio je na autonomnosti koju ostali radovi nisu implementirali, ali su na zanimljive i kreativne načine dizajnirali meke hvataljke. Ovaj ishod potvrđuje kompetitivnu prirodu natjecanja i ističe potrebu za daljnjim unapređenjima u području robotske percepcije i upravljanja.

6.3. Demonstracija na konferenciji hrvatskih robotičara

Nakon uspješnog sudjelovanja na natjecanju, dobili smo priliku prezentirati naš robotski sustav na prvoj Hrvatskoj konferenciji robotike u Čakovcu. Prijelaz s originalnog UR5 robota korištenog na natjecanju na Kinova robot zahtijevao je male prilagodbe sustava. Za potrebe demonstracije iskoristili smo testnu verziju postava korištenu za usavršavanje sustava, što je omogućilo usporedbu funkcionalnosti između ove dvije robotske platforme.



Slika 6.4: Demonstracijski postav na Croatian Robotics Conference u Čakovcu

Migracija sustava na Kinova robota pokazala se iznimno uspješnom - ključne funkcionalnosti sustava (detekcija ploda, algoritmi hvatanja i kontrola sile) zadržale su istu razinu performansi kao na originalnoj platformi.

7. Zaključak

Razvijeni robotski sustav uspješno je testiran u kontroliranom okruženju koje imitira prirodne uvjete rasta malina. Korištenjem umjetnih malina omogućeno je višekratno i pouzdano testiranje algoritama detekcije i berbe. Robotska ruka opremljena mekom hvataljkom pokazala je sposobnost preciznog i nježnog hvatanja plodova, čime je ispunjen osnovni cilj sustava — berba osjetljivog voća bez oštećenja.

Sudjelovanjem na međunarodnom natjecanju Robosoft 2025 sustav je uspješno demonstriran pred stručnom publikom, gdje je prepoznat kao inovativan primjer primjene meke robotike u poljoprivredi. Praktična primjena razvijenog rješenja potvrđuje potencijal ovakvih tehnologija za automatizaciju osjetljivih zadataka u stvarnim uvjetima.

LITERATURA

- [1] Dan-Mihai Rusu, Silviu-Dan Mândru, Cristina-Maria Biriş, Olivia-Laura Petraşcu, Fineas Morariu, and Alexandru Ianosi-Andreeva-Dimitrova. Soft robotics: A systematic review and bibliometric analysis. *Micromachines*, 14(2), 2023.
- [2] Mohsen Annabestani, Behnam Kamare, Majid Shabani, Samuel Videira Magalhaes, Alessio Mondini, and Barbara Mazzolai. A bioinspired multifunctional soft gripper with embedded sensing ability: a potential way for sustainable agricultural harvesting. In *2023 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, pages 182–187, 2023.
- [3] Dario Stuhne Jelena Tabak Marsela Polić Matko Orsag. Design and Prototyping of Soft Finger AI-Enabled Hand (SofIA). *2022 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*, 2022.
- [4] RoboSoft 2025. Robosoft 2025 conference on soft robotics. <https://robosoft2025.org/>, 2025.
- [5] gripper. https://www.iaacblog.com/wp-content/uploads/2020/12/soft_robotic_gripper_thumbnail.jpg
- [6] Ang Chen, Ruixue Yin, Lin Cao, Chenwang Yuan, H.K. Ding, and W.J. Zhang. Soft robotics: Definition and research issues. In *2017 24th International Conference on Mechatronics and Machine Vision in Practice (M2VIP)*, pages 366–370, 2017.
- [7] Jonathan Tirado, Jonas Jørgensen, and Ahmad Rafsanjani. Earthworm-inspired

- multimodal soft actuators. In *2023 IEEE International Conference on Soft Robotics (RoboSoft)*, pages 1–6, 2023.
- [8] R. J. Moreno Masey, J. O. Gray, T. J. Dodd, and D. G. Caldwell. Guidelines for the design of low-cost robots for the food industry. *Industrial Robot: An International Journal*, vol. 37, no. 6, pp. 509–517, 2010.
- [9] J. Sanchez, J.-A. Corrales, B.-C. Bouzgarrou, and Y. Mezouar. Robotic manipulation and sensing of deformable objects in domestic and industrial applications: a survey. *The International Journal of Robotics Research*, vol. 37, no. 7, pp. 688–716, 2018.
- [10] BendLabs. 1-axis flex sensor. https://hr.mouser.com/datasheet/2/983/one_axis_datasheet-1602082.pdf, 2025.
- [11] Arduino. Arduino UNO. <https://docs.arduino.cc/hardware/uno-rev3/>, 2025.
- [12] Intel RealSense. Realsense D435. <https://www.intelrealsense.com/depth-camera-d435/>, 2020.
- [13] Aqeel Anwar. What are Intrinsic and Extrinsic Camera Parameters in Computer Vision? <https://towardsdatascience.com/what-are-intrinsic-and-extrinsic-camera-parameters-in-computer-vision-2022>, 2022.
- [14] OpenCV. Camera Calibration. https://docs.opencv.org/4.x/dc/dbb/tutorial_py_calibration.html, 2025.
- [15] MoveIt! MoveIt! calibration. https://moveit.github.io/moveit_tutorials/doc/hand_eye_calibration/hand_eye_calibration_tutorial.html, 2025.
- [16] Kinova. Kinova. <https://www.kinovarobotics.com>, 2025.

- [17] Universal Robots. UR5. <https://www.universal-robots.com>, 2025.
- [18] Franka Robotics. Franka Emika Panda. <https://franka.de>, 2025.
- [19] Gentofte Hospital. Gentofte hospital improves blood sample handling with ur robots. <https://www.universal-robots.com/case-stories/gentofte-hospital/>, 2025.
- [20] Morgan Quigley, Ken Conley, Brian Gerkey, Josh Faust, Tully Foote, Jeremy Leibs, Rob Wheeler, and Andrew Ng. Ros: an open-source robot operating system. volume 3, 01 2009.
- [21] Robotis. Dynamixel motor docs. <https://emanual.robotis.com/docs/en/dxl/x/xm430-w350/>, 2025.
- [22] Antonio Čogelja, Leticija Crnković. robosoft - GitHub repository. <https://github.com/larics/robosoft/tree/main/src>, 2025.
- [23] ROS. tf. <https://wiki.ros.org/tf/Overview/Transformations>, 2025.
- [24] Specularia abstract. <https://specularia.fer.hr/wp-content/uploads/2019/01/Specularia-Abstract.pdf>, 2019.
- [25] Louise Poubel. Open Source Robotics: Hands on with Gazebo and ROS 2. prezentacija na QCon San Francisco, InfoQ, April 2019.
- [26] Universal Robots A/S. Universal Robots (GitHub Organization). GitHub repository organization, 2025.
- [27] MoveIt Community and PickNik Robotics. Moveit: Open-source motion planning framework for ros. <https://moveit.ai/>, 2025.
- [28] Alex Owen-Hill. How to Calculate a Robot's Forward Kinematics. <https://blog.robotiq.com/>

how-to-calculate-a-robots-forward-kinematics-in-5-easy-steps,
2015.

- [29] Antonio Čogelja, Leticija Crnković. robosoft - GitHub repository. <https://github.com/larics/robosoft/blob/main/README.md>, 2025.

SAŽETAK

Leticija Crnković, Antonio Čogelja

BerryBot: Autonomni podatni robotski sustav za berbu malina

Razvojem automatizacije u poljoprivredi javlja se potreba za preciznim i nježnim sustavima berbe osjetljivog voća poput malina. U ovom radu predstavljen je razvoj i implementacija robotskog sustava za autonomnu berbu malina. Sustav koristi univerzalnu robotsku ruku opremljenu mekom robotskom hvataljkom s integriranim senzorom savijanja te kamerom za detekciju plodova. Cilj projekta bio je razviti nježan i učinkovit sustav za prepoznavanje zrelih malina skrivenih među lišćem i njihovo precizno branje. Razvijen je softver u ROS (Robot Operating System) okruženju koji integrira obradu slike, upravljanje kretanjem robotske ruke te kontrolu hvataljke na temelju povratnih informacija sa senzora savijanja. Detaljno je opisan dizajn i izrada meke robotske hvataljke, algoritmi za detekciju malina te upravljanje sustavom. Provedeni su eksperimenti kako bi se procijenila učinkovitost sustava u detekciji i branju te rezultati demonstriraju potencijal ovakvog pristupa za automatizaciju berbe osjetljivog voća, uzimajući u obzir izazove poput prepoznavanja plodova u prirodnom okruženju.

Ključne riječi: meka robotika, univerzalni robot, ROS, meka hvataljka, senzor savijanja, obrada slike, autonomni sustavi

ABSTRACT

Leticija Crnković, Antonio Čogelja

BerryBot: Autonomous Raspberry Harvesting System Using Soft Robotics and Image Processing

As automation in agriculture advances, the need for precise and gentle harvesting systems of delicate fruits is being introduced. This paper presents the development and implementation of a robotic system for the autonomous harvesting of raspberries. The system utilizes a universal robot arm equipped with a soft robotic gripper with an integrated bending sensor and a camera for fruit detection. The aim of the project was to develop a gentle and efficient system for recognizing raspberries among leaves and picking them precisely. Software was developed in the ROS (Robot Operating System) environment that integrates image processing, robot arm motion control, and gripper control based on feedback from the bending sensor. The design and fabrication of the soft robotic gripper, the raspberry detection algorithms, and the control of the system are described in detail. Experiments were conducted to evaluate the system's effectiveness in detection and harvesting, and the results demonstrate the potential of this approach for the automation of delicate fruit harvesting, taking into account challenges such as fruit recognition in a natural environment.

Keywords: soft robotics, universal robot, ROS, soft gripper, flex sensor, image processing, autonomous systems