Robotski vid za 3D lokalizaciju predmeta rada

Horvat, Ivana

Undergraduate thesis / Završni rad

2010

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:720789

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-05-02**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje

ZAVRŠNI RAD

Ivana Horvat

Zagreb, 2010.

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje

ZAVRŠNI RAD

Mentor:

dr.sc. Bojan Jerbić, red.prof.

Ivana Horvat

Zagreb, 2010.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
Povjerenstvo za završne i diplomske radove
Studij STROJARSTVO
Mehatronika i robotika

Zagreb, 04. prosinac 2009.

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **IVANA HORVAT** Mat. br.: 0035164088
Naslov: **ROBOTSKI VID ZA 3D LOKALIZACIJU PREDMETA RADA**

Opis zadatka:

Roboti za montažu, osim uobičajene programske fleksibilnosti i predviđene funkcionalnosti, sve više preuzimaju šire operativne zadaće. To se prvenstveno odnosi na pripremu dijelova koja prethodi rukovanju i sklapanju. Primjenom odgovarajućih vizijskih sustava i senzora moguće je zamijeniti tradicionalne uređaje za pripremu, kao što su dodavači, uređaji za orijentiranje i pozicioniranje.

U radu je potrebno proučiti FANUC iRVision 3D laserski senzor koji omogućava 3D lokalizaciju objekata. Primijeniti navedeni sustav za otkrivanje pozicije i prostorne orijentacije dijelova pri robotskom rukovanju predmetima rada u nestrukturiranoj okolini. Kod razvoja rješenja voditi računa o funkcionalnoj i upravljačkoj integraciji s postojećim automatskim montažnim sustavom u Laboratoriju za projektiranje izradbenih i montažnih sustava FSBa.

Zadatak zadan: 11. prosinca 2009.

Krajnji rok predaje rada: prosinac 2010.

Zadatak zadao: Prof. dr. sc. Bojan Jerbić

Predsjednik povjerenstva: Prof. dr. sc. Dubravko Majetić

Sažetak rada

U ovom završnom radu bilo je potrebno proučiti kako funkcionira Fanucov *i*R Vision 3D laserski senzor. Predmet rada bio je bazni dio grebenaste sklopke tvrtke Končar, koji se nalazio u nestrukturiranoj okolini (u kutiji). Pomoću 3D laserskog senzora, određivala se pozicija i orijentacija predmeta. Prema tim podacima robotska se ruka dovodila u položaj za hvatanje, a kasnije i za odlaganje zadanog predmeta. Tim postupkom, završen je prvi korak automatskog montažnog procesa grebenaste sklopke, koji se radio u Laboratoriju za projektiranje izradbenih i montažnih sustava pri Fakultetu strojarstva i brodogradnje u Zagrebu.

Sadržaj

Popis slika V
Popis oznaka i mjernih jedinica fizikalnih veličina VII
Izjava VIII
Zahvala IX
1. Uvod 1
2. Opis problema 3
3. Osnovne operacije 6
3.1. Referentna i stvarna pozicija predmeta 8
3.2. Fiksna kamera i kamera montirana na robotsku ruku 10
3.3. Korisnički koordinatni sustav i koordinatni sustav alat 10
4. Kalibracija kamere 12
4.1. Kalibracijska mreža 12
4.2. Proces kalibracije 13
4.3. 2D kalibracija 14
4.4. 3D kalibracija 15
5. Vizijski proces 18
5.1. 2D vizijski proces 18
5.1.1. GPM lokacijski alat 19
5.1.2. Postavljanje referentne pozicije kod 2D vizijskog procesa 22
5.2. 3D vizijski proces 23
5.2.1. 3DL ravninski komandni alat 24
5.2.2. Postavljanje referentne pozicije kod 3D vizijskog procesa 26
6. Program 27
6.1. Dijagram toka 27
6.2. Program 30
6.2.1. 2D vizijski program 30
6.2.2. 3D vizijski program 30
6.2.3. Glavni program 32
6.3. Slikoviti prikaz programa 33
7. Zaključak 40
8. Literatura 41

Popis slika

Slika 1: Usporedba kamere i ljudskog oka 1
Slika 2: Grebenasta sklopka tvrtke Končar 3
Slika 3: Prednja i stražnja strana baznog dijela grebenaste sklopke 4
Slika 4: Kutija u kojoj se nalaze predmeti 4
Slika 5: Prikaz sustava u Laboratoriju za projektiranje izradbenih i montažnih sustava 5
Slika 6: Početno sučelje vizijskog procesa 6
Slika 7: Vision Setup 7
Slika 8: Vision Runtime 8
Slika 9: Referentna i stvarna pozicija predmeta 9
Slika 10: Pomak fiksnog okivra 9
Slika 11: Primjer fiksne kamere i kamere montirane na robotsku ruku 10
Slika 12: Kalibracijska mreža 12
Slika 13: Bitne točke za proces kalibracije 13
Slika 14: Sučelje opcije *Grid Pattern Calibration* 14
Slika 15: Opcije 2D kalibracije 15
Slika 16: Sučelje opcije 3D Vision Calibration 16
Slika 17: Opcije 3D kalibracije 16
Slika 18: Sučelje 2D vizijskog procesa 18
Slika 19: GPM lokacijski alat 19
Slika 20: Opcija Training Mask 20
Slika 21: Opcija Emphasis Area 21
Slika 22: Lokacijski parametri 21
Slika 23: Stupnjevi slobode 22
Slika 24: Određivanje referentne pozicije 22
Slika 25: Sučelje 3D vizijskog procesa 23
Slika 26: 2D postavke u 3D vizijskom procesu 24
Slika 27: Postavke lasera u 3D vizijskom procesu 24
Slika 28: Opcija 3DL laserski komandni alat 25
Slika 29: Opcija 2D-3D Gap 25
Slika 30: Referentni podaci 26
Slika 31: Početna točka 33
Slika 32: Početak 2D vizijskog procesa 33
Slika 33: 3D vizijski proces 34
Slika 34: Točka prilaska 34
Slika 35: Točka hvatanja 35
Slika 36: Otvaranje hvataljke 35
Slika 37: Podizanje predmeta 36
Slika 38: Povratak u točku prilaska 36
Slika 39: Odvođenje u točku odlaganja 37
Slika 40: Točka odlaganja 37
Slika 41: Zatvranje hvataljke 38

Slika 42: Odlaženje robotske ruke prema početnoj točki 38
Slika 43: Povratak u početnu točku 39

Popis oznaka i mjernih jedinica fizikalnih veličina

L	duljina [mm]
α	kut [°]
t	vrijeme [s]

Izjava

Izjavljujem da sam ovaj rad izradila samostalno služeći se stečenim znanjem, navedenom literaturom, uz nadzor i stručne savjete mentora prof. dr. sc. Bojana Jerbića.

_____

Zahvala

Prije svega, željela bih se zahvaliti mentoru, prof. dr. sc. Bojanu Jerbiću, što mi je, svojim korisnim savjetima, pomogao u izradi ovog završnog rada. Dao mi je priliku da naučim nešto novo i vrlo zanimljivo, te sam mu na tome zahvalna.

Koristim ovu priliku da se zahvalim Barbi, na svim savjetima i velikoj potpori, ne samo tijekom izrade ovog rada, već i cijelog studiranja. Hvala što si mi pokazao da ništa nije nemoguće.

Također, željela bih se zahvaliti svim prijateljima i kolegama koji su mi bili velika potpora.

Na kraju, najveće hvala mojoj mami, što mi je, u svim trenucima mog života, bila čvrsti oslonac i velika potpora u svemu što radim.

1. Uvod

Strojevi, koji mogu osjetiti okolinu u kojoj se nalaze i u njoj izvesti određene zadatke, vrlo su korisni u mnogim područjima kao što su industrijsko sklapanje i nadzor, snimanje svemira, rengensko skeniranje... Oni pomažu u zadacima koji su rutinski, monotoni ili čak opasni za ljude. Problem koji se javlja prilikom korištenja tih strojeva je taj što je takve strojeve gotovo nemoguće automatizirati bez sposobnosti vizualizacije. Većina zadataka u industrijskom sklapanju zahtijevaju korištenje vida. Vizualna percepcija je toliko izravna i od nas ne zahtijeva mnogo truda te je to razlog zbog kojeg je dosta teško zamisliti automatizaciju tog procesa. [1]

Uspoređujući vizualni proces između ljudi i strojeva moguće je pronaći neke sličnosti. Početni korak ljudskog vida započinje u mrežnici oka, točnije, fotoreceptori u mrežnici skupljaju svijetlost i šalju signale u mrežu neurona. Ti fotoreceptori nazivaju se štapići i čunjići. Štapići su osjetljivi na svjetlo, a čunjići na boju i detalje. Oni proizvode električne impulse koji putuju u mozak. Mozak obrađuje te impulse te daje informacije o tome što mi vidimo. U tom procesu, mnoge komponente ljudskog mozga i oka moraju raditi zajedno.

Oko, kao ljudski „aparat“ za vizualni proces, je vrlo slično kameri. Oboje sakupljaju svjetlo i pretvaraju ga u sliku koja se kasnije može interpretirati. Snopom svjetlosti upravlja se pomoću leća. Očna leća projicira okrenutu sliku na mrežnicu na isti način kako to radi kamera na film. Uloga leće je da sakuplja snopove svjetlosti koji se reflektiraju od nekakvog objekta i usmjerava ih prema mrežnici ili filmu kako bi se stvorila stvarna slika. Sam postupak stvaranja slike je poprilično jednostavan. Poznata je činjenica da svjetlost drugačije putuje kroz različite medije; puno brže putuje kroz zrak, nego staklo. Dakle, može se zaključiti da leća smanjuje brzinu putovanja svjetlosti. Kad zrake svjetlosti, pod nekim kutem, uđu u leću, jedan dio zrake će dosegnuti leću prije drugog i taj dio će prije smanjiti svoju brzinu putovanja. [2]

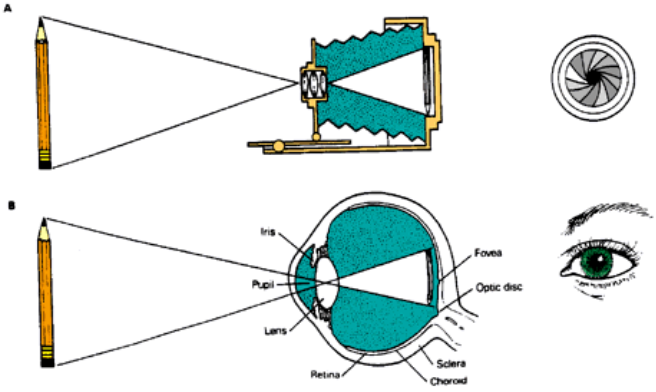

Slika 1: Usporedba kamere i ljudskog oka

Vizualna percepcija strojeva spada u područje umjetne inteligencije kojoj je cilj stvoriti strojeve koji se ponašaju inteligentno. Inteligentno ponašanje se temelji na učenju nekakvih obrazaca. Strojevi, kao i ljudi, na isti način pronalaze objekte u okolini. Recimo, tražeći određenu knjigu, nikad ne čitamo puni naslov svake knjige, već brzo pregledavamo knjige u potrazi za prvim slovom ili nekim od prvih slova naslova koji tražimo. Ili, ako je prijatelj kojeg čekamo visok i plavokos, tražit će se samo ta dva obilježja. Dolazi se do zaključka da se nebitne informacije nastoje ne obrađivati, već se zahvaćaju samo neki aspekti objekta koji su nužni za obavljanje uspješne pretrage. To područje psihologije naziva se prepoznavanje oblika i na njemu se temelji svaki vizijski proces. [3]

Govoreći općenito o vizijskim procesima, može se reći da su Fanucovi roboti vrsta robota kod kojih se primjenjuje sistem „ponavljanja naučenog“. Dakle, u takvom sustavu, robota se određeni zadaci nauče unaprijed te on te zadatke izvodi točno onako kako ih je prije naučio. Robotski program je upravo to- niz naredbi koje mu govore što treba napraviti. Sam proces izrade programa se naziva učenje, a čin izvođenja ponavljanje. Na neki način, ta vrsta robota limitirana je onim što je prije naučeno, to jest napisano u programu. To znači slijedeće; ako se želi da robot svaki put rukuje predmetom na isti način, potrebno je staviti taj predmet uvijek na istu poziciju.

iR Vision je vizijski senzor konstruiran u svrhu eliminiranja takvih ograničenja. On mjeri poziciju određenog predmeta pomoću kamera i prema tome prilagođava pokrete robota tako da on može rukovati predmetom na isti način na koji je programiran, iako je pozicija predmeta drugačija od naučene.

2. Opis problema

U završnom radu bilo je potrebno proučiti Fanucov *i*R Vision 3D laserski senzor koji omogućava određivanje pozicije i prostorne orijentacije predmeta u nesređenoj okolini. Predmeti rada nalazili su se u kutiji, dakle, njihova orijentacija i pozicija tijela bila je proizvoljna u svim stupnjevima slobode.

Kao predmet rada, uzeta je grebenasta sklopka tvrtke Končar, točnije, njezin bazni dio.

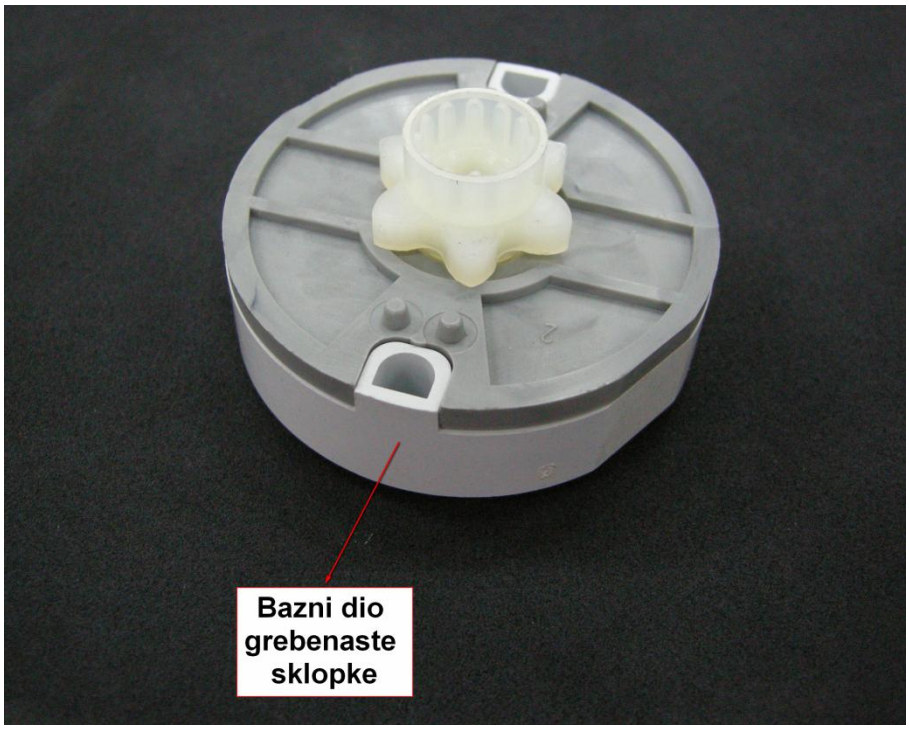

Slika 2: Grebenasta sklopka tvrtke Končar

Prednja i stražnja strana baznog dijela grebenaste sklopke prikazane su na slici 2. Može se vidjeti da su strane baznog dijela potpuno različite, te je bilo potrebno naučiti robota da hvata samo one predmete koji su bili postavljeni na prednju, tj. „pravu“ stranu. Kako se to napravilo, detaljnije je opisano u potpoglavlju 4.1.1..

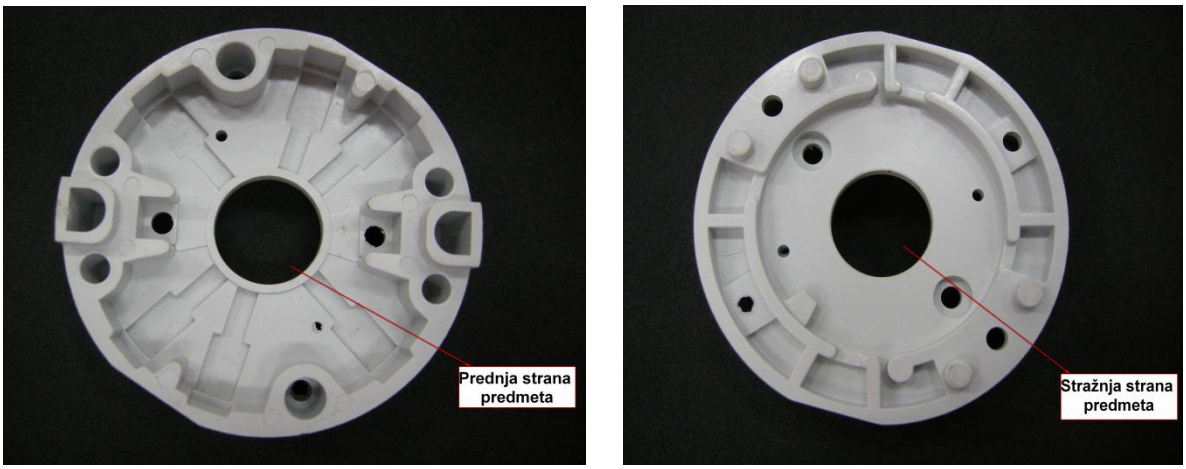

Slika 3: Prednja i stražnja strana baznog dijela grebenaste sklopke

Predmeti rada nalazili su se u kutiji koja je bila duboka cca 70 mm i sa svih strana obložena crnom spužvom. Crna spužva omogućila je jako dobar kontrast između predmeta rada, koji je bio sive boje, i podloge. Kutija, u kojoj su se nalazili predmeti, nije smjela biti preduboka zbog toga što bi bila prevelika razlika u visini između kalibracijske ravnine i ravnine u kojoj su se nalazili predmeti rada. Time ne bi bilo moguće izvršiti hvatanje predmeta rada.

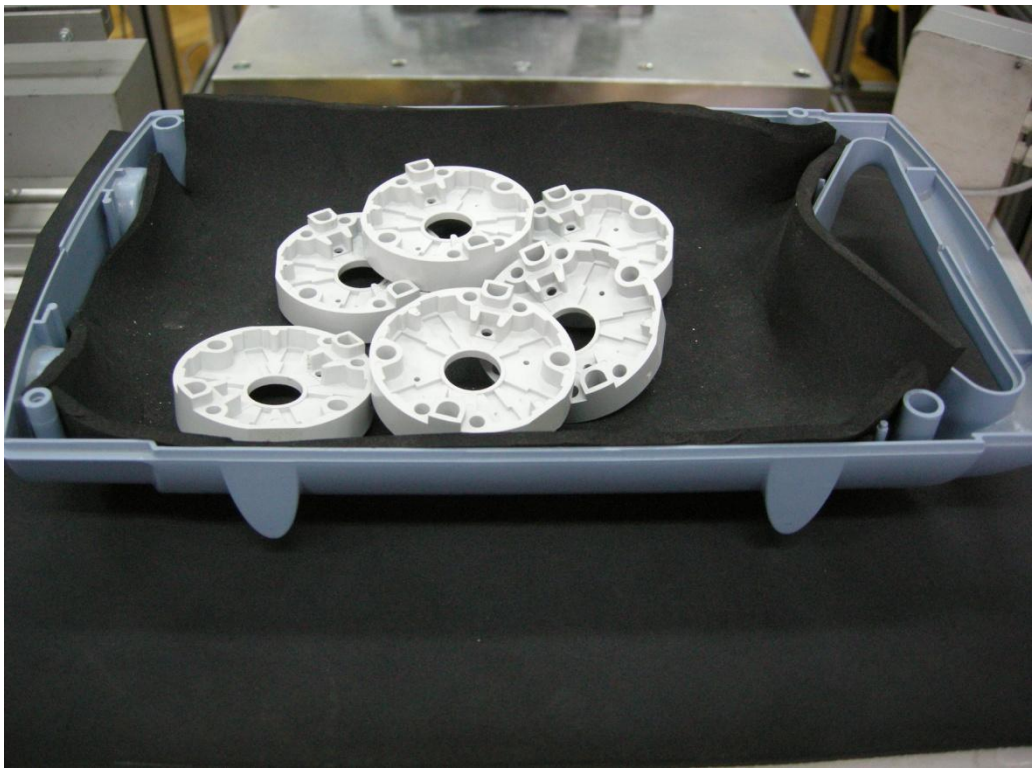

Slika 4: Kutija u kojoj se nalaze predmeti

Predmeti rada hvatali su se pomoću posebno konstruirane hvataljke, nalik pinceti. Ona je izvršni član Fanucovog robota M-10*i*A.[4] Korištenje klasične hvataljke, u ovom slučaju nije bilo moguće, zato što se s njom ne bi mogao omogućiti dobar prihvat predmeta koji su bili nagnuti pod nekim kutem.

Nakon izrade cijelog vizijskog procesa (poglavlje 5.) i definiranja referentnih podataka, bilo je potrebno, unošenjem karakterističnih točaka, naučiti robotsku ruku položaj predmeta. Karakteristične točke su: točka slikanja, točka prilaska, točka hvatanja te točka odlaganja. Odlučeno je da će se predmet hvatati tako da zatvorena hvataljka svaki put uđe u provrt, koji se nalazi u središtu predmeta, te se otvori.

Cijeli sustav, pomoću kojeg se napravio ovaj završni rad, nalazi se u Laboratoriju za projektiranje izradbenih i montažnih sustava, na Fakultetu strojarstva i brodogradnje u Zagrebu. Sustav je prikazan na slici 4.

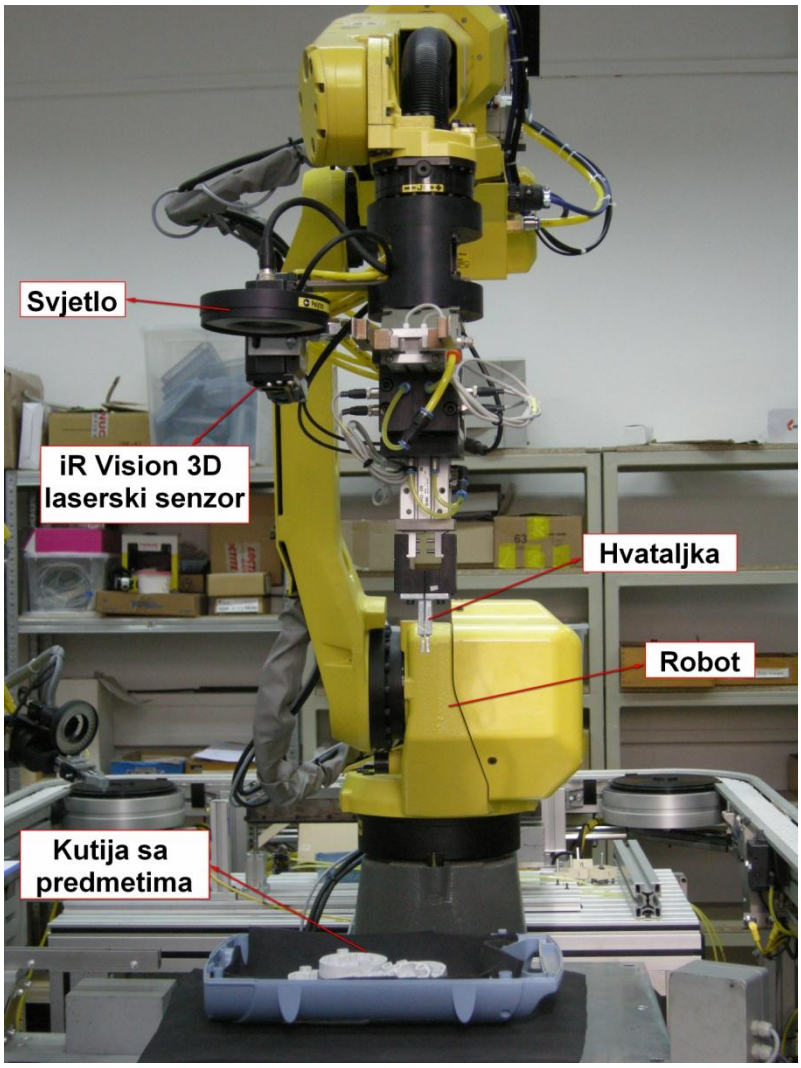

Slika 5: Prikaz sustava u Laboratoriju za projektiranje izradbenih i montažnih sustava

3. Osnovne operacije

Vizijski proces se postavlja uz pomoć računala koje je spojeno na robotsku upravljačku jedinicu, preko Ethernet mreže. Prije svega, potrebno je predstaviti početnu stranicu. Do nje se dolazi na slijedeći način; otvara se Intrenet Explorer te se upisuje IP adresa. Pojavljuje se sučelje koje je prikazano na slijedećoj slici.

Slika 6: Početno sučelje vizijskog procesa

Ispod opcije *i*R Vision vidljiva su tri linka:

- *Vision Setup*
- *Vision Log*
- *Vision Runtime*

Opcija *Vision Setup* se može definirati kao glavna za postavljanje vizijskog procesa. Kad se ona odabere, pojavi se prozor prikazan na slijedećoj slici.

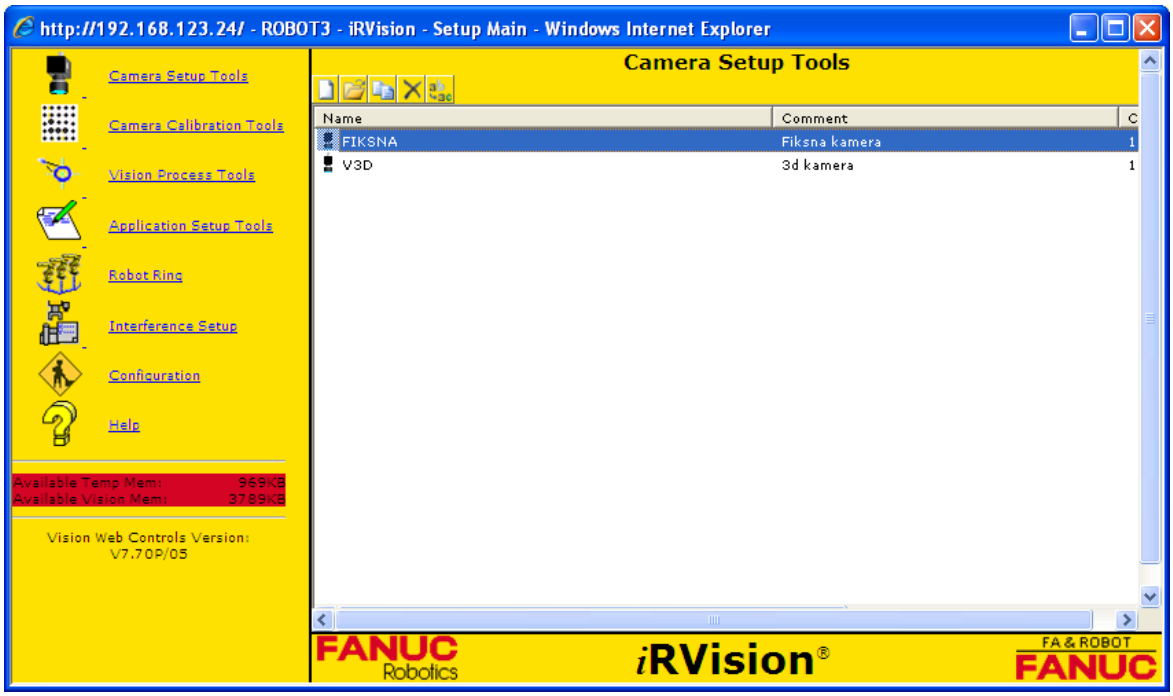

Slika 7: Vision Setup

Kako je vidljivo iz slike 3. , u opciji *Vision Setup* moguće je odabrati slijedeće:

- Alate za postavljanje kamere
- Alate za kalibraciju kamere
- Alate za vizijski proces
- Alate za postavljanje aplikacije
- Poziv robota
- Vizijsko praćenje
- Konfiguracija
- Pomoć

Slijedeća opcija je *Vision Log*. Pomoću opcije *Vision Log*, ***i***R Vision može zapisati podatke vezane uz samo izvođenje vizijskih procesa.

Na kraju, potrebno je reći nekoliko riječi o opciji *Vision Runtime*. Tijek izvođenja vizijskog procesa moguće je pratiti na računalu ili na ***i***Pendantu. ***i***Pendant je upravljačka jedinica. Tijek izvođenja procesa koji je praćen na računalu, prikazan je na slici 4.

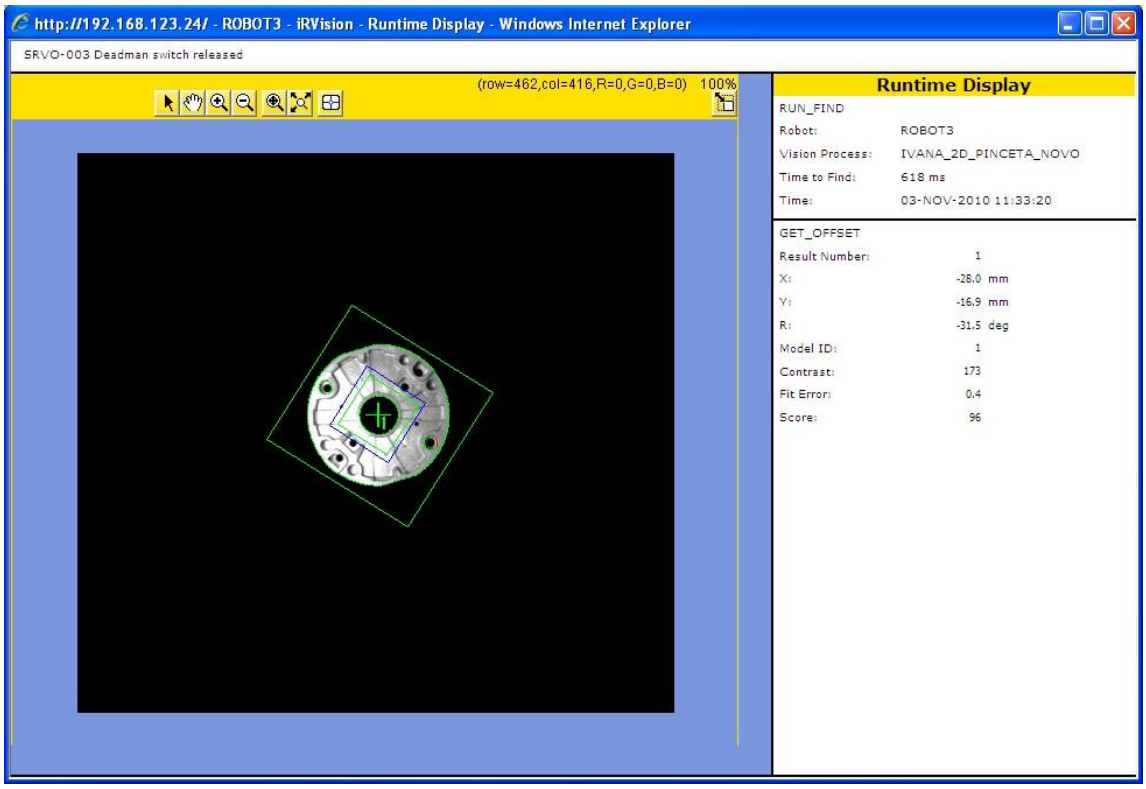

Slika 8: Vision Runtime

Sa slike 4. vidljivo je da se tijekom procesa mogu dobiti informacije kao što su: vrijeme potrebno za pronalazak predmeta, pozicija i orijentacija predmeta, kontrast, rezultat pronalaska, greška...

Potrebno je detaljnije objasniti nekoliko pojmova kako bi se mogao shvatiti daljnji tekst završnog rada.

3.1. Referentna i stvarna pozicija predmeta

Podaci pomaka su oni koji određuju poziciju robota koja služi za pomicanje predmeta. Oni se računaju između pozicije predmeta koja je određena prilikom programiranja robota i trenutne pozicije. Referentna pozicija je ona koju robot nauči prilikom učenja programa, a stvarna pozicija je ona u kojoj se trenutno nalazi predmet. Podaci pomaka su, zapravo, razlika između te dvije pozicije. Kad se uči robotski program, *i*R Vision mjeri referentnu poziciju koju automatski pohranjuje.

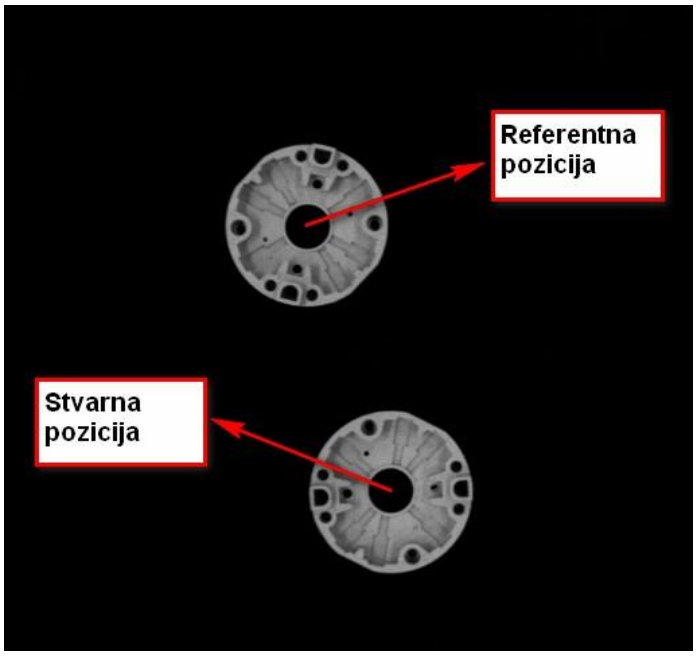

Slika 9: Referentna i stvarna pozicija predmeta

Potrebno je reći da postoje dvije vrste pomaka; pomak fiksnog koordinatnog sustava i pomak koordinatnog sustava alata. U ovom završnom radu rađen je pomak fiksnog koordinatnog sustava te će ta metoda biti detaljnije objašnjena u nastavku. Uz pomoć fiksnog koordinatnog sustava, pomak predmeta se mjeri u koordinatnom sustavu koji je fiksan u odnosu na bazu robota. Kamerom se gleda i mjeri pozicija predmeta koji se nalazi na fiksnoj podlozi. Robot prilagođava naučenu poziciju trenutnoj, tako da može manipulirati predmetom (npr. podignuti ga).

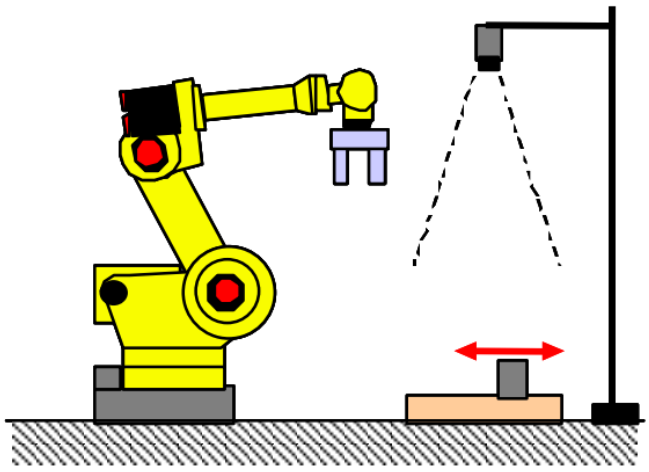

Slika 10: Pomak fiksnog koordinatnog sustava

3.2. Fiksna kamera i kamera montirana na robotsku ruku

Fiksna kamera mora biti montirana na vrh fiksne strukture, recimo stupa. U ovoj metodi, kamera uvijek ima isti sliku sa iste udaljenosti. Jedna od prednosti ovakve metode je ta, što dolazi do skraćivanja vremena procesa, zato što *i*R Vision može slikati proces dok robot obavlja neku drugu radnju.

Ako je kamera montirana na zglob robota, mjerenja između kamere i predmeta mogu se raditi na različitim udaljenostima i pri različitim lokacijama. Prilikom toga, *i*R Vision računa poziciju predmeta, s time da uzima u obzir pomak kamere koji se javlja kao posljedica pomicanja robotske ruke.

Primjeri kad je kamera na fiksnoj poziciji i kad je montirana na robotsku ruku prikazani su na slijedećoj slici.

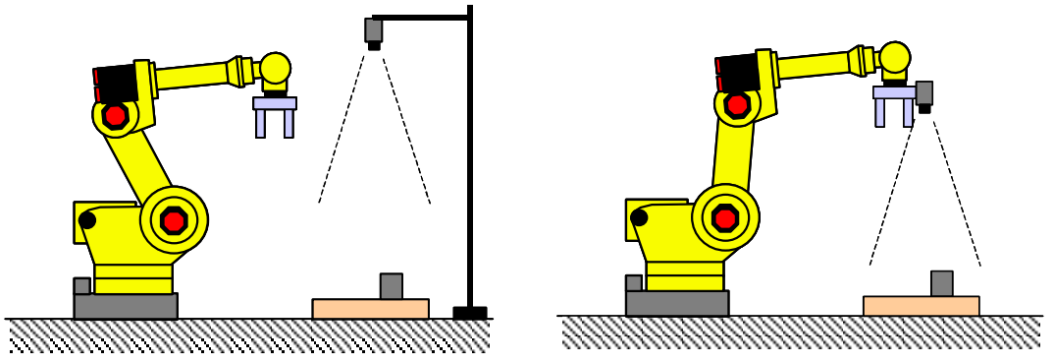

Slika 11: Primjer fiksne kamere i kamere montirane na robotsku ruku

3.3. Korisnički koordinatni sustav i koordinatni sustav alat

Fanucovi roboti su roboti koji ponavljaju ono što su prije naučili. Dakle, u robotskim sustavima koji ne koriste vizijski proces, nije potrebno određivati i upotrebljavati ove koordinatne sustav, zato što robot samo ponavlja naučene pokrete bez obzira koliko su oni točno postavljeni.

S druge strane, koordinatni sustavi su vrlo važni prilikom korištenja vizijskih procesa. Ako oni nisu dobro postavljeni, doći će do velikih grešaka prilikom rada zato što se pomoću ovih koordinatnih sustava određuju pozicija i položaj robota. Korisnički koordinatni sustav određuje radni prostor robota, dok koordinatni sustav alata predstavlja poziciju i orijentaciju alata. Njegovo ishodište se još naziva TCP (Tool Center Point/ Središnja točka alata).

Korisnički koordinatni sustav definira radni prostor robota. Podaci pomaka u vizijskom sustavu su svi temeljeni na korisničkom koordinatnom sustavu te je vrlo važno da se robota što točnije nauči njegova pozicija. U 2D vizijskim aplikacijama, korisnički koordinatni sustav ima još jednu vrlo važnu ulogu. On definira 2D ravninu, koja mora biti paralelna sa XY ravninom, u 3D stvarnom svijetu.

Koordinatni sustav alata definira poziciju i orijentaciju robotskog alata. U robotskim sustavima koji koriste vizijski proces, vrlo je važno što točnije odrediti središnju točku alata, prilikom učenja korisničkog koordinatnog sustava. Ako ona nije dobro određena, dolazi do smanjenja točnosti cijelog procesa.

4. Kalibracija kamere

Prije samog vizijskog procesa potrebno je utvrditi odnos između koordinata na slici i koordinata u realnom svijetu. To se postiže procesom kalibracije.

4.1. Kalibracijska mreža

Standardna metoda koja se koristi za kalibraciju kamere je kalibracija uz pomoć kalibracijske mreže. Kalibracijska mreža je skup međusobno jednako udaljenih crnih točaka koje se nalaze na bijeloj podlozi i koja ima kvadratni oblik. U ovom radu, korištena je kalibracijska mreža 20x20mm.

Kad se mreža, poput ove na slici dolje, gleda kroz kameru, *i*R Vision automatski postavlja odnos između kalibracijske mreže i kamere, distorziju leće, udaljenost fokusa...

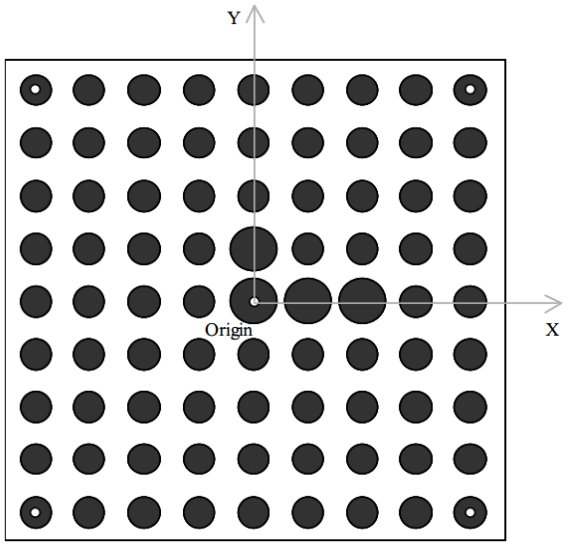

Slika 12: Kalibracijska mreža

Veliki krugovi, koji se nalaze u blizini centra kalibracijske mreže, označavaju središte mreže te smjerove koordinatnih osi kako je prikazano na slici.

Mali, bijeli krugovi označavaju mjesta koja se moraju dotaknuti, prilikom procesa kalibracije, sa središnjom točkom alata.

Prilikom kalibracije, kalibracijska se mreža može postaviti na stol ili može biti montirana na kraj robotske ruke. U ovom radu, kalibracijska mreža bila je postavljena na stol te će zato biti detaljnije objašnjena ova metoda. Ako je kalibracijska mreža postavljena na stol, moraju se osigurati uvjeti da ne dođe do pomicanja mreže prilikom procesa kalibracije. U tom se slučaju, podaci, vezani uz položaj kalibracijske mreže u odnosu na tijelo robota, moraju postaviti u korisnički koordinatni sustav.

4.2. Proces kalibracije

Postoje dvije metode koje se koriste prilikom kalibriranja kalibracijske mreže; prva metoda se temelji na tome da se fizički nauči kalibracijska mreža uz pomoć metalnog vrška koji se postavlja na kraj alata robotske ruke. Druga metoda se, pak, temelji na tome da se uz pomoć kamere, bez dodira, mjeri odnos između kalibracijske mreže i kamere. U ovom radu rađena je prva metoda.

Kad se postavi metalni vršak na kraj alata robotske ruke, na *i*Pendantu se odabire opcija *User Frame Setup/ Four Points* i fizički se dodire kalibracijska mreža u četiri karakteristične točke koje su prikazane na slijedećoj slici.

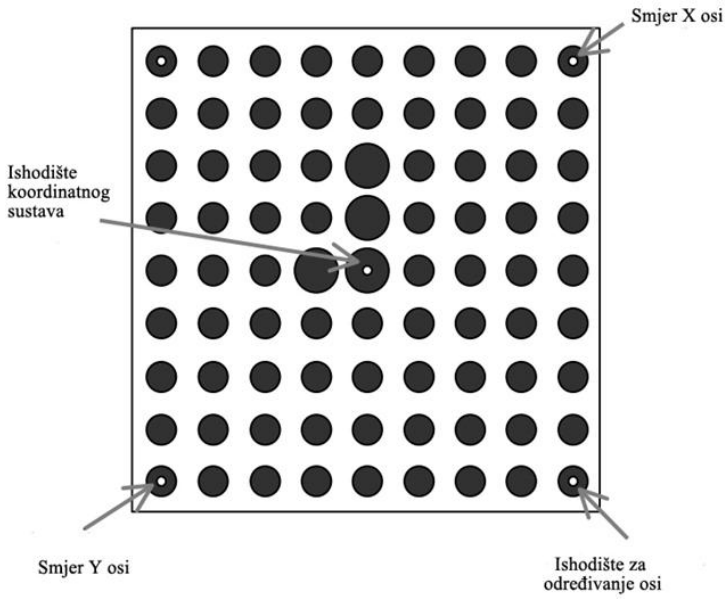

Slika 13: Bitne točke za proces kalibracije

Vrh robotskog alata prvo se dovodi u donju desnu točku, kako bi se označilo ishodište koordinatnog sustava i smjerovi koordinatnih osi. Zatim se dovodi u gornju desnu točku, kako bi se označio smjer X osi, nadalje u donju lijevu točku, za određivanje smjera Y osi i na kraju u središte kalibracijske mreže, kako bi se pohranila pozicija središta sustava.

4.3. 2D kalibracija

Nakon što su se pohranili podaci u korisnički koordinatni sustav (slučaj kad je kalibracijska mreža fikisirana za stol), potrebno je napraviti 2D kalibraciju tako da se otvori Internet Explorer i odabere opcija *Grid Pattern Calibration* kako je prikazano na slici 10.

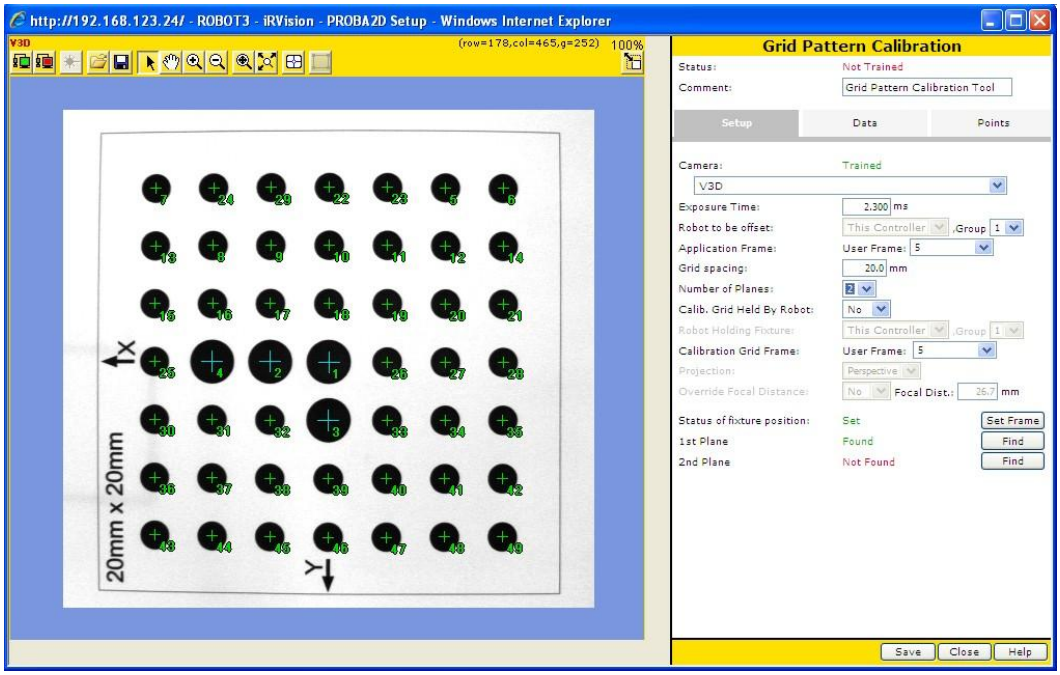

Slika 14: Sučelje opcije *Grid Pattern Calibration*

Na desnoj strani sučelja moguće je podesiti različite opcije koje su detaljnije prikazane na slici 11. Potrebno je odabrati kameru za kalibraciju, vrijeme ekspozicije, korisnički koordinatni sustav, razmak između točaka kalibracijske mreže, kalibracijski koordinatni sustav i broj ravnina u kojima će se raditi kalibracija. Za kameru se odabire jedna od postavki koja je prije postavljena. Vrijeme ekspozicije potrebno je prilagoditi svjetlosnim uvjetima tako da se na zaslonu dobije slika dovoljno dobre kvalitete. Isto tako, potrebno je izmjeriti koliki je razmak između točaka kalibracijske mreže. Broj ravnina određuje se na temelju toga kako je montirana kamera kojom se vrši kalibracija. Ako je montirana na robotsku ruku, odabiru se dvije ravnine, inače jedna. Na kraju upisuje se broj koordintanih sustava (korsničkog i kalibracijskog) koji se koristi za 2D kalibraciju.

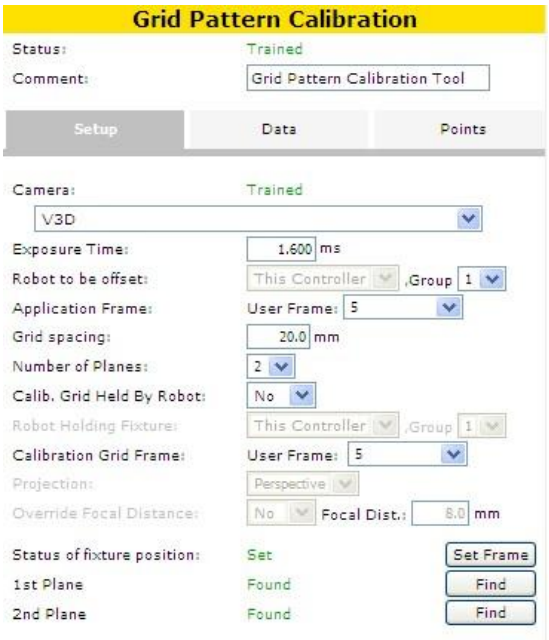

Slika 15: Opcije 2D kalibracije

Nakon odabiranja postavki, potrebno je kamerom pronaći kalibracijsku mrežu. Za slikanje kalibracijske mreže, odabire se crveni monitor koji se nalazi na glavnom sučelju ove opcije. Preporuka je postaviti kalibracijsku mrežu što bliže središtu slike kako bi točnost izračuna pozicije kalibracijske mreže bila što veća. Kad je slikanje gotovo, mora se pritisnuti tipka *Find*, kako bi se pohranili podaci za prvu ravninu. Ako je kalibracijska mreža pričvršćena za stol, nakon slikanja prve ravnine, potrebno je podići kameru za cca 150 mm, kako bi se promijenila udaljenost između kamere i kalibracijske mreže, te napraviti drugo slikanje. Kad je slikanje završeno, u središtu svake točke pojavljuje se zeleni križić koji pokazuje da je kalibracijska točka pronađena.

4.4. 3D kalibracija

3D kalibracija je metoda koja se koristi prilikom kalibracije 3D laserskog senzora. Za 3D kalibraciju potrebno je odabrati opciju *3D Laser Vision Calibration*. Sučelje koji se koristi za 3D kalibraciju prikazano je na slijedećoj slici.

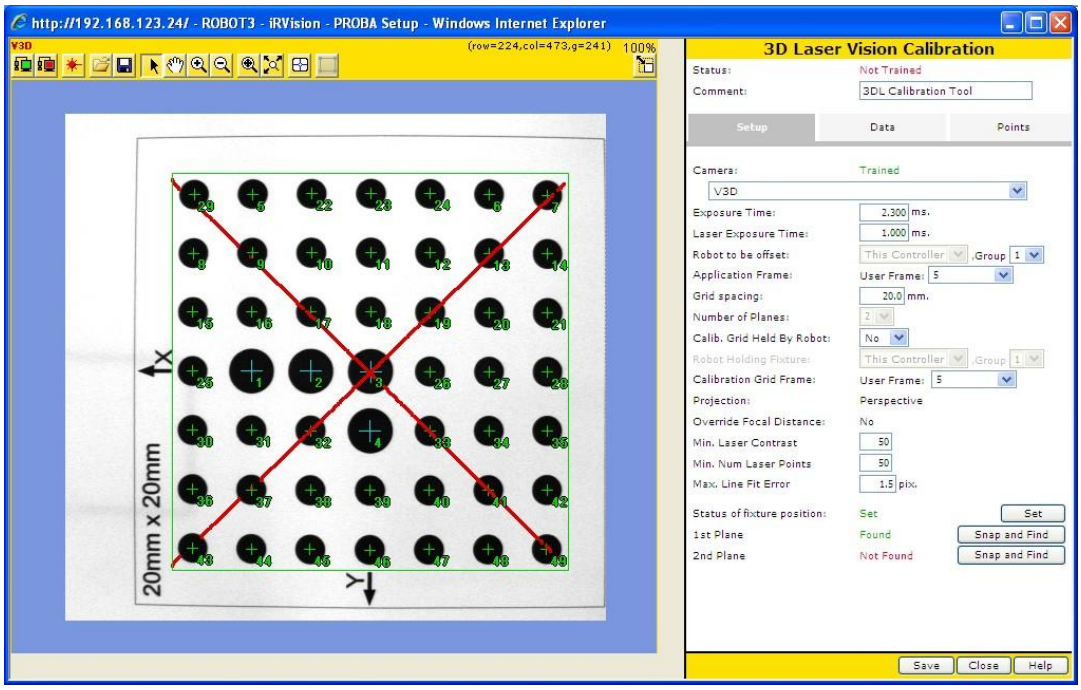

Slika 16: Sučelje opcije 3D Vision Calibration

Među opcijama koje su detaljnije prikazane na slici 13. potrebno je podesiti kameru za kalibraciju, vrijeme ekspozicije kamere i lasera, korisnički i kalibracijski koordinatni sustav, razmak između točka kalibracije, broj kalibracijskih ravnina, minimalni kontrast lasera te minimalni broj laserskih točaka koji su potrebni za kalibraciju. Mnoge od opcija iste su kao i kod 2D kalibracija. Pomoću opcije minimalni kontrast lasera određuje se granica kontrasta koja je prikladna za pronalaženje slijeda laserskih točaka. Može se odrediti vrijednost između 1 i 254.

Slika 17: Opcije 3D kalibracije

Nakon odabiranja odgovarajućih postavki, potrebno je postaviti laserski senzor na cca 350mm od kalibracijske mreže te pritisnuti tipku *Snap and Find*. Nakon toga, potrebno je dovesti prozor za traženje u položaj da se unutar njega nalaze točke kalibracijske mreže.

Kad se koristi kalibracijska mreža koja je fiksirana za stol, kalibracija se mora napraviti u dvije kalibracijske ravnine. Prilikom učenja prve ravnine, preporuka je da se snop laserskih zraka dovede blizu središta kalibracijske mreže kako je prikazano na slici 12.

Zbog toga je potrebno laserski senzor podignuti na visinu od cca 450mm, kako bi se odredila druga kalibracijska ravnina. Postupak određivanja druge kalibracijske ravnine je isti kao i za prvu ravninu. [5]

5. Vizijski proces

Nakon postavljanja kalibracijske mreže te njezinog kalibriranja, potrebno je napraviti vizijski proces za odabrani predmet. Ako se predmet nalazi u XY ravnini mora se napraviti 2D vizijski proces, kako bi se odredio njegov položaj i orijentacija. No, kad se predmet nalazi nagnut pod nekim kutem, nakon 2D vizijskog procesa, radi se 3D vizijski proces. U ovom radu, 2D vizijski proces je korišten kako bi se odredio položaj i orijentacija predmeta, dok se 3D vizijskim procesom, određivao kut nagiba.

5.1. 2D vizijski proces

2D vizijski proces je proces pomoću kojeg se otkrivaju položaj i orijentacija predmeta koji se nalazi u XY ravnini. Kao izravna posljedica otkrivanja položaja predmeta, javlja se pomak robota u tu poziciju. Sučelje koji se koristi za 2D vizijske procese prikazano je na sljedećoj slici.

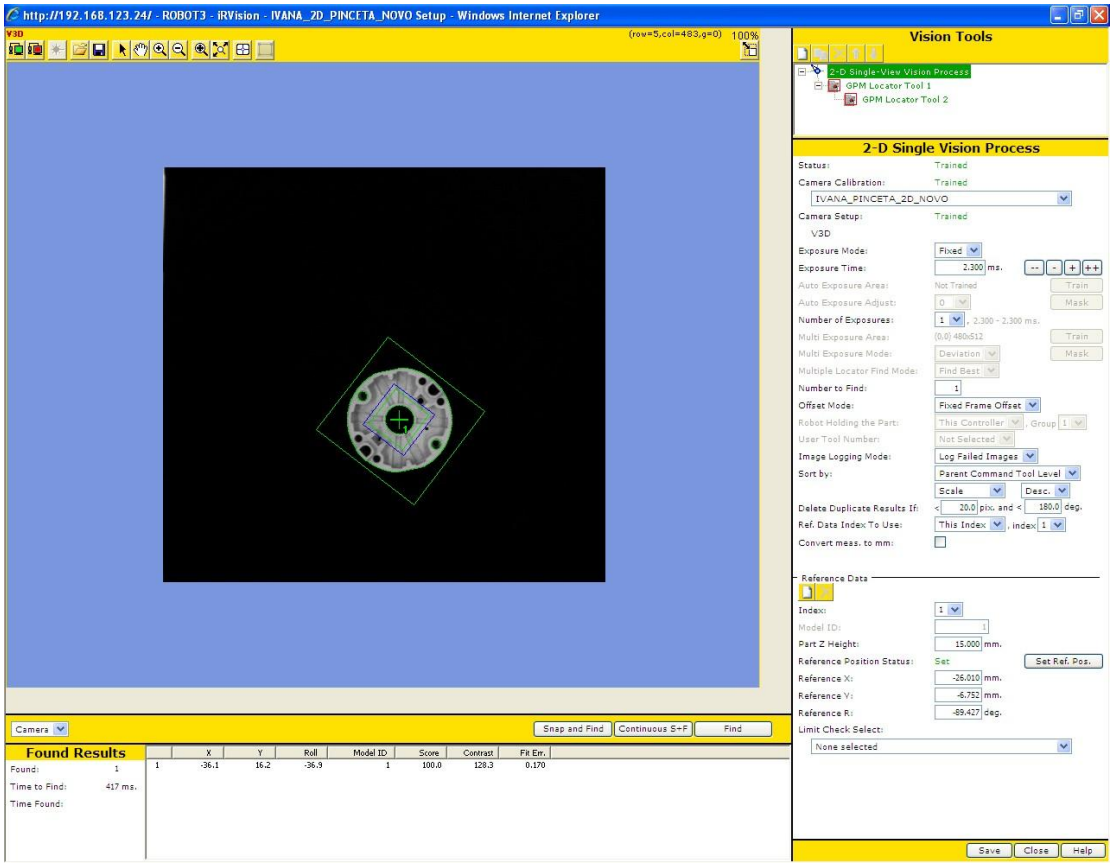

Slika 18: Sučelje 2D vizijskog procesa

Među postavkama vizijskog procesa, odabire se odgovarajuća kaibracija kamere za proces, postavlja se vrijeme ekspozicije ovisno o svjetlosnim uvjetima, upisuje se broj dijelova koji se mora pronaći i model prema kojem se robot pomiče u određenu poziciju. Da bi vizijski proces bio valjan, potrebno je definirati GPM lokacijski alat.

5.1.1. GPM lokacijski alat

GPM lokacijski alat se smatra jezgrom *i*R Vision-a. On traži uzorak koji se podudara sa već prije naučenim uzorkom i otkriva trenutnu poziciju predmeta.

Potrebno je odrediti geometrijske značajke prema kojima će se taj predmet prepoznavati. Da bi se to napravio, mora se pritisnuti tipka *Teach Pattern*. Pojavljuje se crveni okvir pomoću kojeg označimo predmet za kojeg želimo naučiti uzorak.

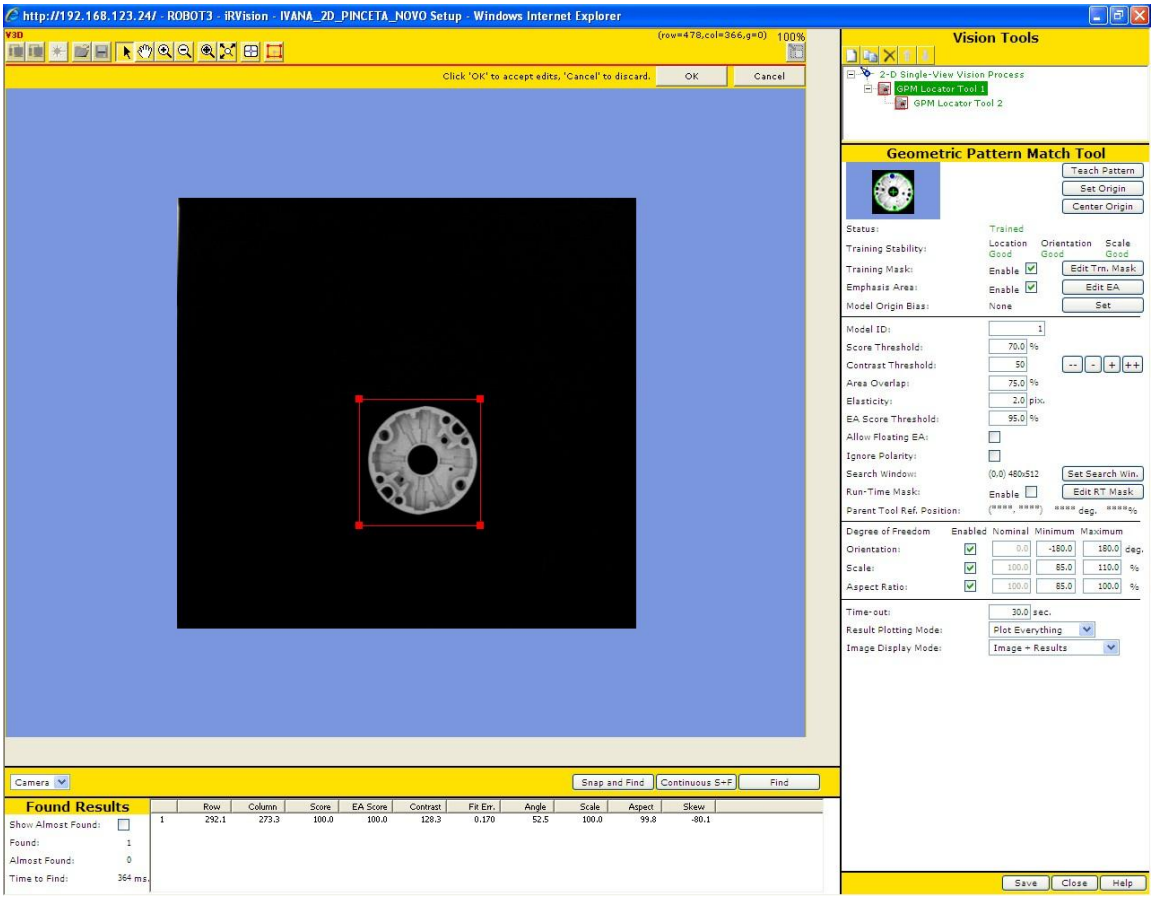

Slika 19: GPM lokacijski alat

Uz pomoć alata *Training Mask* označavaju se one značajke koje se ne žele vidjeti prilikom prepoznavanja predmeta. Skrivaju se ona područja koja u nestabilna; ona koja se i pri maloj promjeni svjetlosnih uvjeta teže prepoznaju. Ostavljaju se ona područja koja su ključna za prepoznavanje položaja i orijentacije predmeta.

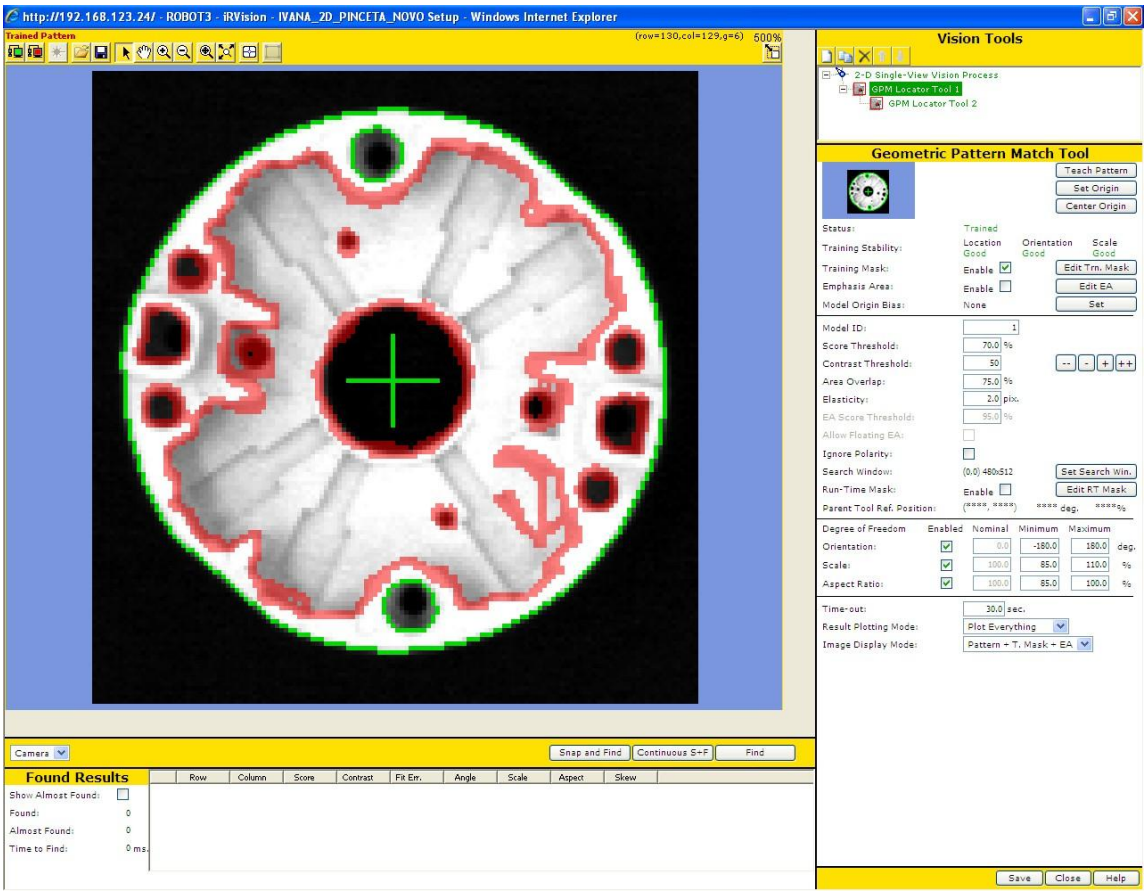

Slika 20: Opcija Training Mask

Ponekad se koristi opcija *Emphasis Area* koja omogućava da se naglasi neka karakteristika predmeta koja je ključna za njegov položaj i orijentaciju. Bitno je napomenuti da se predmet neće pronaći, ako to područje nije vidljivo, bez obzira što je, recimo, veliki dio predmeta vidljiv. U završnom radu je korištena ova opcija, kako bi se naglasila razlika između prednje i stražnje strane predmeta (željelo se postići da robot hvata samo pravilno postavljene predmete). Mora se reći da time nije narušeno pronalaženje predmeta zato što je on simetričan.

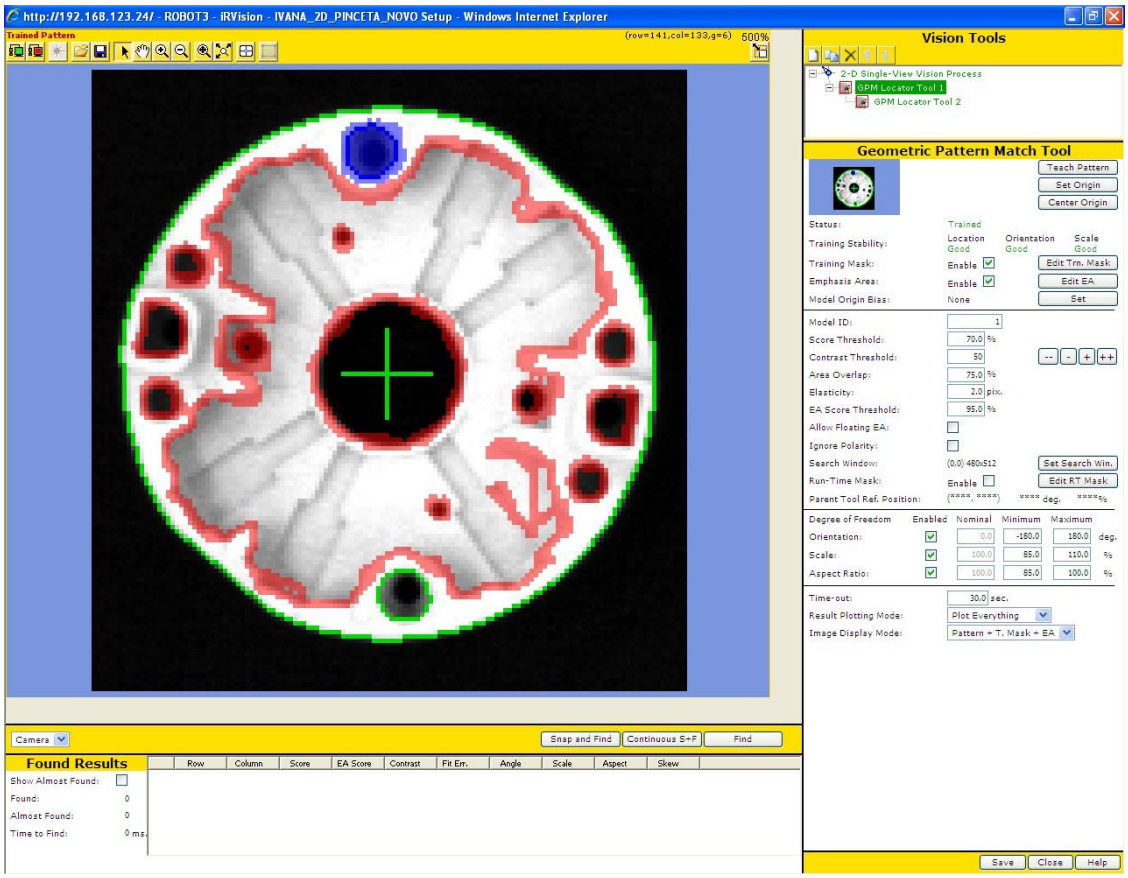

Slika 21: Opcija Emphasis Area

Za uspješno pronalaženje predmeta potrebno je podesiti lokacijske parametre kao što su granice pronalaženja rezultata položaja i kontrasta te elastičnost. Položaj predmeta je točno određen ako je rezultat pronalaženja jednak ili veći od prije određene vrijednosti. Ako su granice pronalaženja kontrasta blizu jedna drugoj, može se dogoditi da se predmet ne prepozna zbog promjenjivih svjetlosnih uvjeta koji daju različitu osjenčanost predmeta. Što se tiče opcije elastičnosti, potrebno je odrediti koliko geometrija uzorka na slici može odstupati od naučenog.

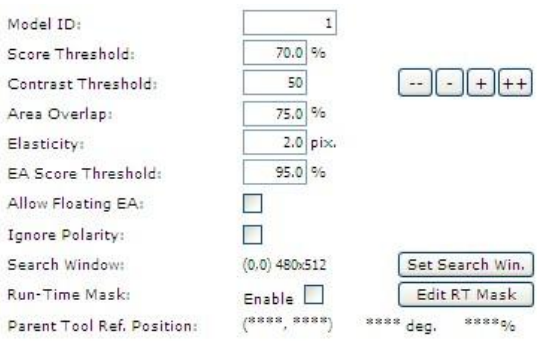

Slika 22: Lokacijski parametri

Nakon podešavanja lokacijskih parametara, moraju se odrediti stupnjevi slobode. Orijentacija naučenog predmeta je 0°, a *i*R Vision će tražiti uzorak predmeta koji može biti zaokrenut u nekakvim granicama od naučenog. Isto tako, *i*R Vision će tražiti one predmete čiji se rezultat nalazi unutar granica koje su određene u opcijama *Scale* i *Aspect Ratio*. Brzina pretraživanja će najviše ovisiti o minimalnim i maksimalnim vrijednostima granica. Ako je razmak između njim manji, vrijeme pretraživanja će biti kraće.

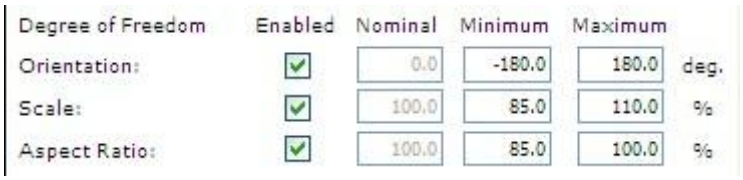

Slika 23: Stupnjevi slobode

5.1.2. Postavljanje referentne pozicije kod 2D vizijskog procesa

Posljednji korak je definiranje referentnih podataka i referentnog položaja. Kao jedna od bitnijih stavki pojavljuje se *Part Z Height* kojom se određuje visina predmeta. Ona je vrlo važna zato što predstavlja udaljenost između XY ravnine korisničkog koordintanog sustava i ravnine u kojoj se mjeri pozicija predmeta. Određivanjem te vrijednosti moguće je povezati podatke pomaka, koji su dobiveni pomoću kamere, sa onima koji su napravljeni u realnom svijetu.

Pomoću tipke *Snap and Find* automatski se upisuju vrijednosti X i Y osi i rotacije oko osi Z. Pritiskom na tipku *Set reference position* definiramo referenti položaj u određenom koordinatnom sustavu.

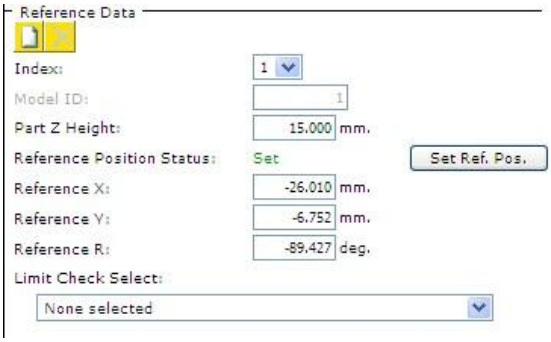

Slika 24: Određivanje referentne pozicije

Nakon definiranja referentnih podataka, potrebno je naučiti robtsku ruku, unošenjem karakterističnih točaka, položaj predmeta. Pri tome se predmet ne smije pomicati.

5.2. 3D vizijski proces

Nakon 2D vizijskog procesa, kojim se odabrao predmet i odredila njegova pozicija, potrebno je napraviti 3D vizijski proces pomoću kojeg se određuje 3D položaj (nagib) i orijentacija. Prema dobivenim podacima, prilagođava se kretanje robotske ruke. Za 3D vizijski proces, u glavnom izborniku odabire se opcija *3DL Single View Vision Proces*, te se pojavi sučelje prikazano na sljedećoj slici.

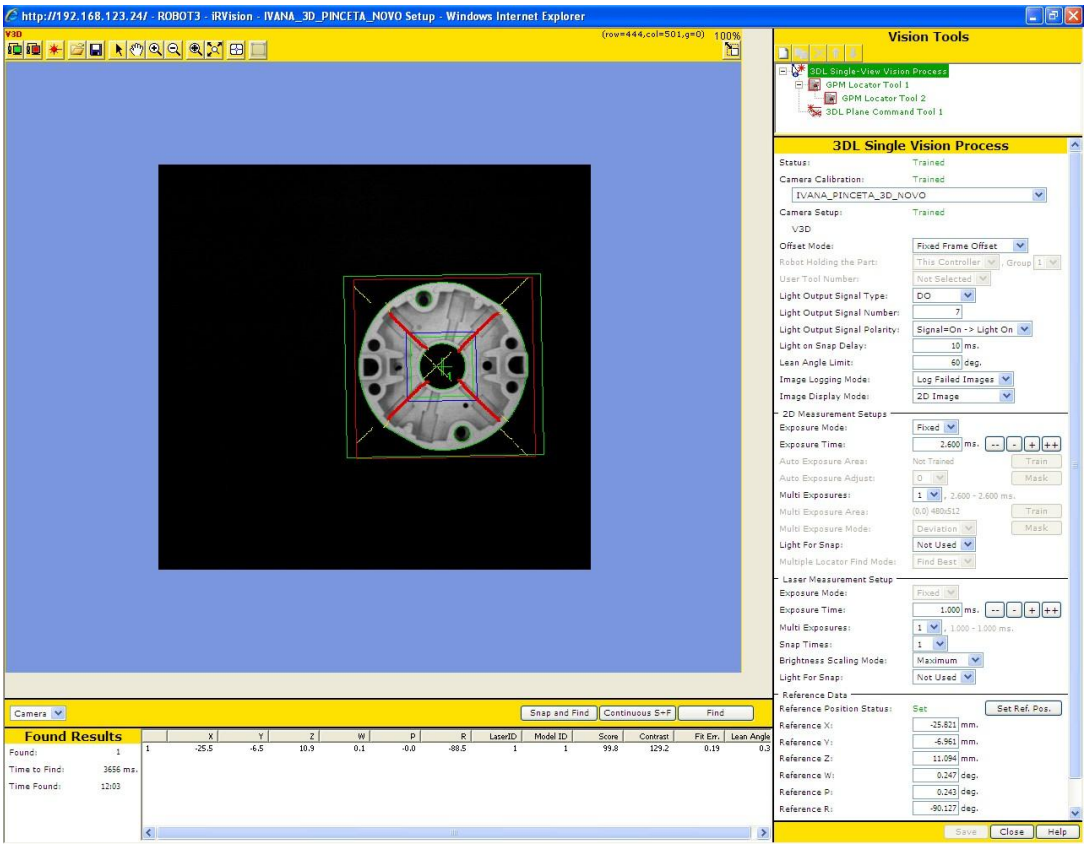

Slika 25: Sučelje 3D vizijskog procesa

Među postavkama, odabire se već prije napravljena 3D kalibracija, način računanja pomaka predmeta u prostoru (*Fixed Frame Offest*), mogućnost paljenja ili gašenja svjetla tijekom vizijskog procesa kako bi se povećala stabilnost, granica nagiba kuta (dio koji je nagnut pod većim kutem od granice nagiba, neće se pronaći)...

Kod 2D postavki potrebno je odrediti vrijeme ekspozicije s obzirom na svjetlosne uvjete, da li da se upali svjetlo prilikom slikanja 2D slike i način na koji da se izvedu lokacijski alati, ako ih postoji više.

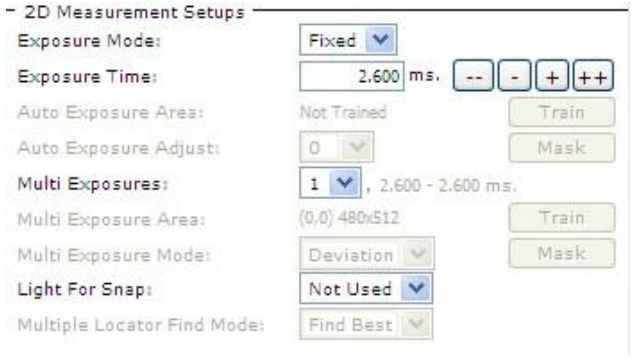

Slika 26: 2D postavke u 3D vizijskom procesu

Kod postavki lasera, potrebno je odrediti vrijeme ekspozicije, koliko puta se želi napraviti slika tijekom jednog ekspozicijskog vremena te da li da se koristi svjetlo tijekom slikanja ili ne.

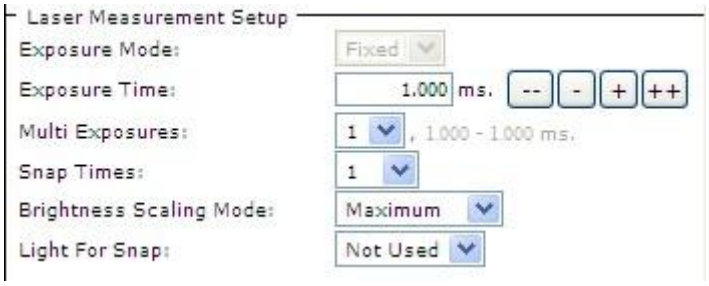

Slika 27: Postavke lasera u 3D vizijskom procesu

GPM lokacijski alat se koristi na isti način koji je bio prikazan kod 2D vizijskog procesa te ga nije potrebno detaljnije objašnjavati.

5.2.1. 3DL ravninski komandni alat

3DL ravninski komandni alat mjeri poziciju i nagib predmeta tako da osvijetli njegov ravninski dio pomoću lasera, tj. 3D laserskog senzora. Ako se odabere ta opcija, pojavi se sučelje prikazano na slici 24.

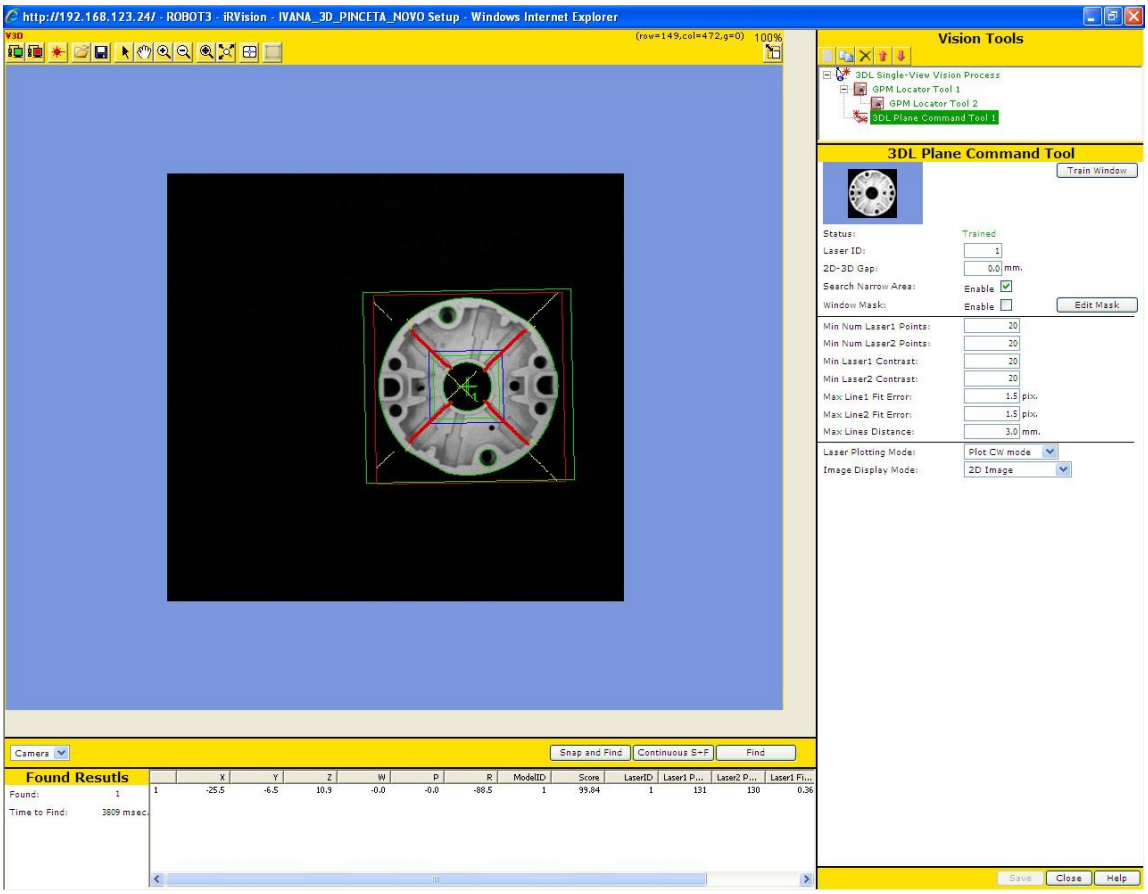

Slika 28: Opcija 3DL laserski komandni alat

Potrebno je postaviti predmet u središte slike, a to se radi na vrlo jednostavan način; uključe se opcije *Live Image* (zeleni monitor) i *Laser* te se predmet fizički dovede u centralnu poziciju, s time da se središte predmeta podudara sa sjecištem laserskih zraka. Kako bi se prekinulo imitiranje slike uživo, pritisne se crveni monitor. Nakon toga, odabere se opcija *Train Window* te se pomoću crvenog pravokutnika poveća područje predmeta koje se želi naučiti. Ako postoji razlika u visini, između ravnine u kojoj je učen GPM lokacijski alat i ravnine koja se mjeri laserom, potrebno je to naznačiti u opciji *2D-3D Gap*.

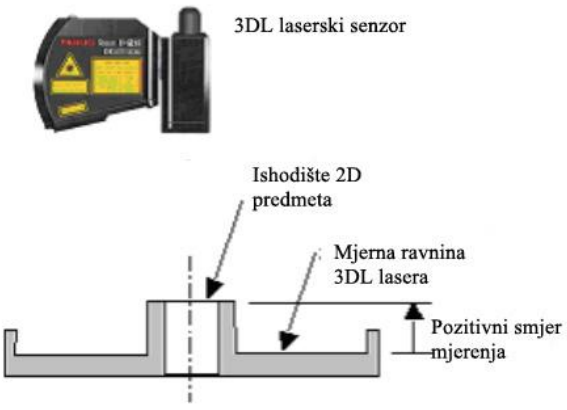

Slika 29: Opcija 2D-3D Gap

Uz pomoć opcije *Search Narrow Area* povećava se broj točaka koje se koriste prilikom mjerenja, no bitno je napomenuti, da se omogućavanjem ove opcije, produljuje vrijeme vizijskog procesa. Ako se neki dijelovi predmeta žele „isključiti“ tijekom procesa, to se može napraviti pomoću opcije *Window Mask*.

Na kraju, potrebno je prilagoditi lokacijske parametre. Ako zbog, malog mjernog područja ili razlike u kontrastu, dolazi do različitih rezultata prilikom pronalaska predmeta pomoću lasera, moguće je smanjiti broj laserskih točaka, kako bi se uklonio taj problem. Isto tako, povećanjem vrijednosti opcije *Max. Line Fit Error* moguće je postići nešto bolje rezultate.

5.2.2. Postavljanje referentne pozicije kod 3D vizijskog procesa

Vrijednost pomaka predmeta se računa između njegove referentne i trenutne pozicije. Da bi se odredila referentna pozicija, potrebno je napraviti slijedeće; postaviti predmet blizu središta slike i pritisnuti tipku *Snap and Find*. Automatski dolazi do upisivanja referentnih podataka kako je prikazano na slici 26.

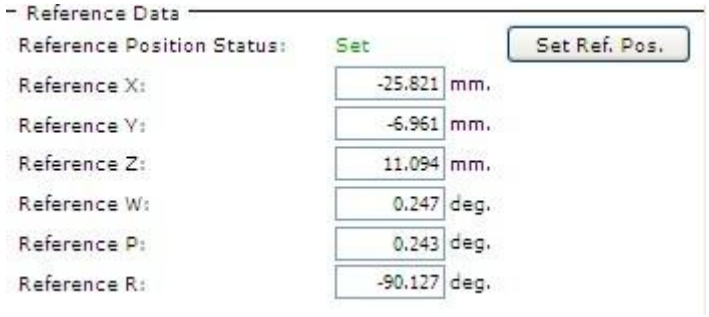

Slika 30: Referentni podaci

Pritiskom na tipku *Set Reference Position* podaci se pohranjuju i postaju referentne vrijednosti. Na kraju, potrebno je naučiti robota referentnu poziciju predmeta tako da ga se dovede u nju, s time da se predmet ne dotakne.

6. Program

6.1. Dijagram toka

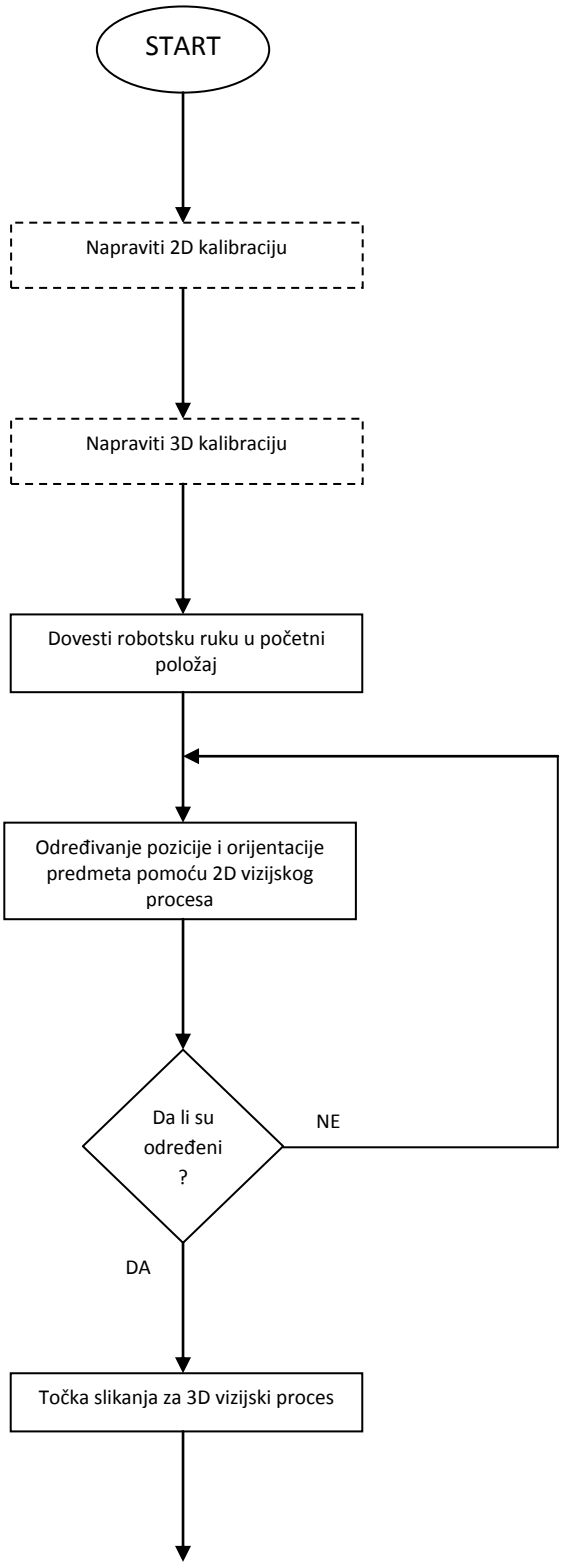

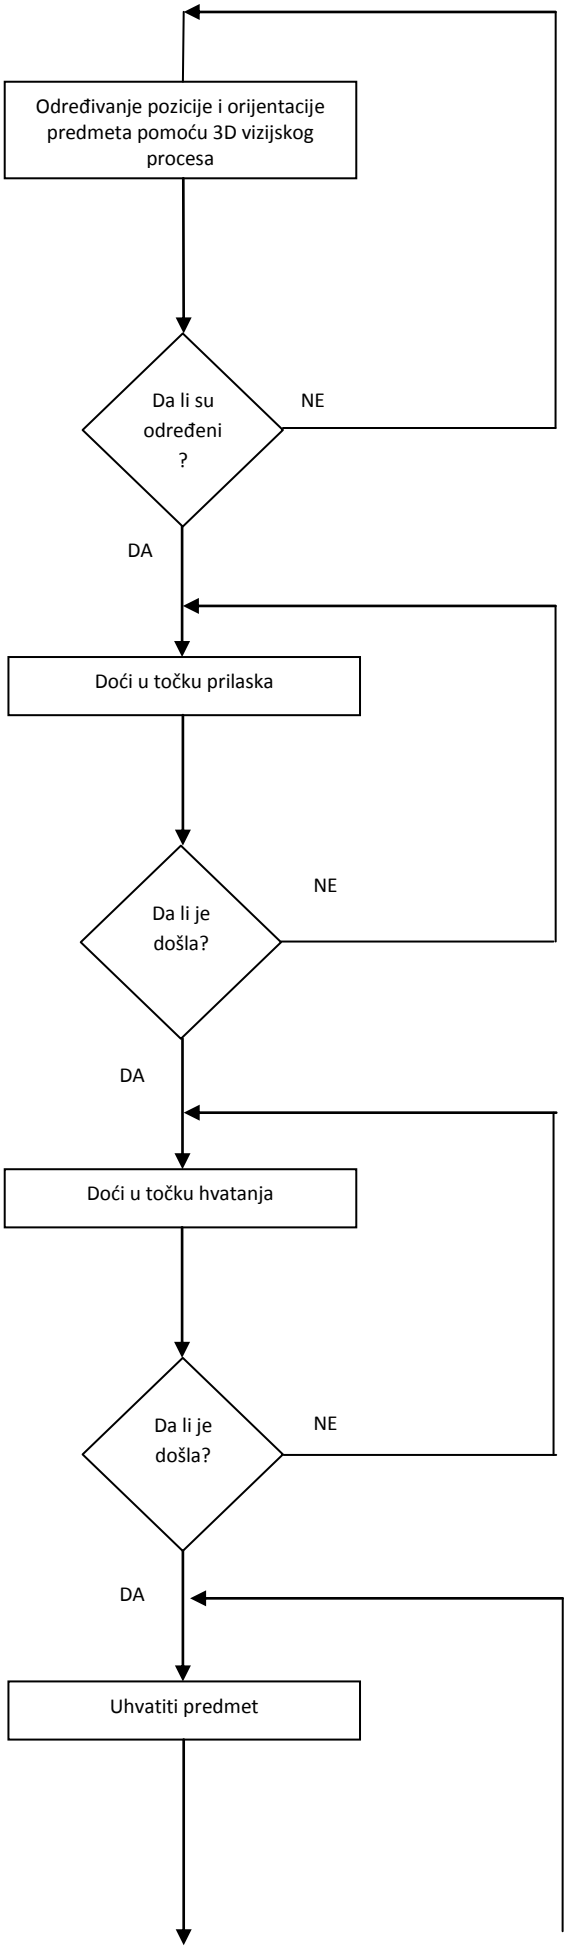
Određivanje pozicije i orijentacije predmeta pomoću 3D vizijskog procesa
Da li su određeni ?
NE
DA
Doći u točku prilaska
Da li je došla?
NE
DA
Doći u točku hvatanja
Da li je došla?
NE
DA
Uhvatiti predmet

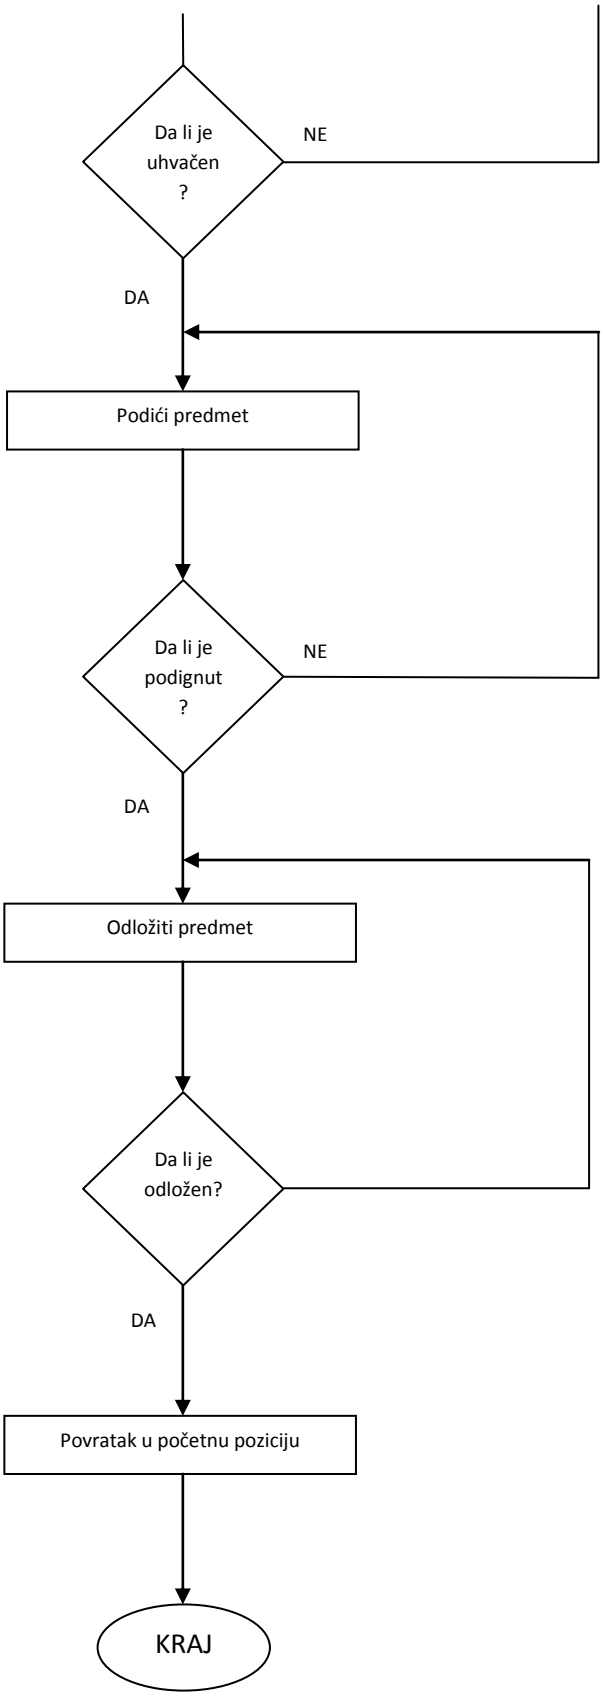

Legenda simbola

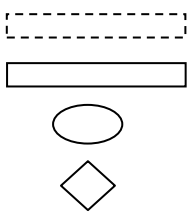

6.2. Program

6.2.1. 2D vizijski program

```
   1:  UFRAME_NUM=5 ;
   2:  UTOOL_NUM=10 ;
   3:   ;
   4:   ;
   5:  CALL GR_SK_CL    ;
   6:   ;
   7:J P[1] 100% FINE    ;
   8:  LBL[1] ;
   9:  DO[7]=PULSE,2.0sec ;
  10:   ;
  11:  VISION RUN_FIND 'IVANA_2D_PINCETA_NOVO'    ;
  12:  VISION GET_OFFSET 'IVANA_2D_PINCETA_NOVO'
       VR[1] JMP LBL[1] ;
  13:   ;
  14:J P[2] 100% FINE VOFFSET,VR[1]    ;
  15:   ;
  16:  CALL IVANA_PINCETA_3D    ;

/POS

P[1]{
   GP1:
        UF : 5, UT : 10,              CONFIG : 'N U T, 0, 0, -1',
        X =   -46.571  mm,     Y =    -5.718  mm,     Z =   506.651  mm,
        W =   179.653 deg,     P =     1.079 deg,     R =   173.828 deg
};
P[2]{
   GP1:
        UF : 5, UT : 10,              CONFIG : 'N U T, 0, 0, -1',
        X =   -12.267  mm,     Y =    -3.376  mm,     Z =   300.725  mm,
        W =   179.652 deg,     P =     1.077 deg,     R =   173.829 deg
};
/END
```

6.2.2. 3D vizijski program

```
   1:  UFRAME_NUM=5 ;
   2:  UTOOL_NUM=4 ;
   3:   ;
   4:  VISION RUN_FIND 'IVANA_3D_PINCETA_NOVO'    ;
   5:  VISION GET_OFFSET 'IVANA_3D_PINCETA_NOVO'
       VR[1] JMP LBL[99] ;
   6:   ;
   7:  CALL GR_SK_CL    ;
   8:   ;
   9:J P[1] 100% FINE VOFFSET,VR[1]    ;
  10:L P[2] 30mm/sec FINE VOFFSET,VR[1]    ;
  11:  WAIT    .40(sec) ;
  12:  CALL GR_SK_OP    ;
```

```
  13:L P[1] 30mm/sec FINE VOFFSET,VR[1]    ;
  14:   ;
  15:   ;
  16:L P[3] 80mm/sec FINE    ;
  17:J P[4] 100% FINE    ;
  18:L P[5] 100mm/sec FINE    ;
  19:   ;
  20:  CALL GR_SK_CL    ;
  21:   ;
  22:L P[6] 100mm/sec FINE    ;
  23:J P[7] 100% FINE    ;
  24:   ;
  25:  LBL[99] ;

/POS

P[1]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =   -26.561  mm,     Y =    -8.251  mm,     Z =    46.271  mm,
        W =     -.009 deg,     P =    -2.129 deg,     R =    -6.072 deg
};
P[2]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =   -25.700  mm,     Y =    -8.019  mm,     Z =   -11.716  mm,
        W =     -.009 deg,     P =    -2.128 deg,     R =    -6.071 deg
};
P[3]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =   -27.828  mm,     Y =    -8.573  mm,     Z =   129.756  mm,
        W =     -.008 deg,     P =    -2.127 deg,     R =    -6.071 deg
};
P[4]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =  -168.775  mm,     Y =   369.220  mm,     Z =   157.132  mm,
        W =     -.009 deg,     P =    -2.126 deg,     R =    -6.072 deg
};
P[5]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =  -163.891  mm,     Y =   370.490  mm,     Z =  -170.050  mm,
        W =     -.009 deg,     P =    -2.124 deg,     R =    -6.074 deg
};
P[6]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =  -169.570  mm,     Y =   368.988  mm,     Z =   208.693  mm,
        W =     -.009 deg,     P =    -2.123 deg,     R =    -6.074 deg
};
P[7]{
   GP1:
        UF : 5, UT : 4,        CONFIG : 'N U T, 0, 0, -1',
        X =  -110.072  mm,     Y =   142.796  mm,     Z =   252.685  mm,
        W =     -.009 deg,     P =    -2.121 deg,     R =    -6.074 deg
};
/END
```

6.2.3. Glavni program

```
1:  LBL[99] ;
2:   ;
3:  CALL IVANA_PINCETA_2D    ;
4:   ;
5:  JMP LBL[99] ;
```

6.3. Slikoviti prikaz programa

Početna točka

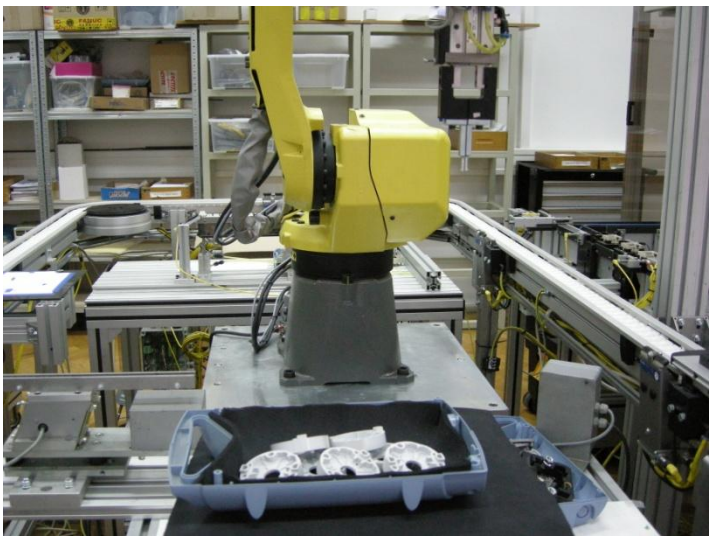

Slika 31: Početna točka

Paljenje svjetla- 2D vizijski proces

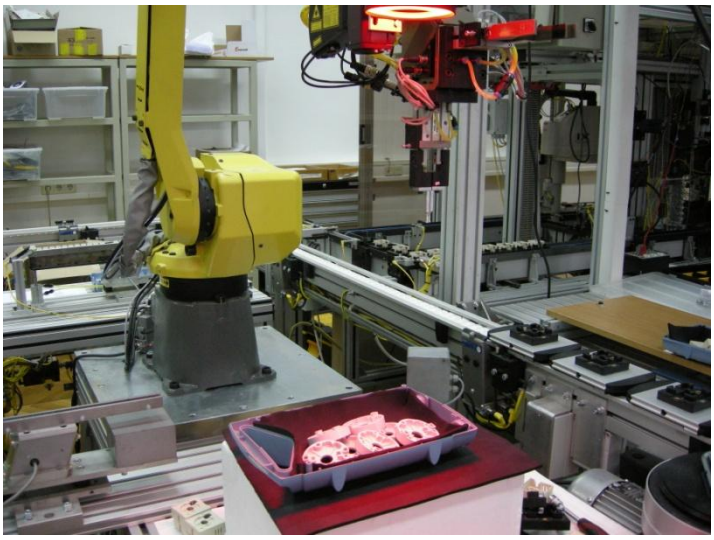

Slika 32: Početak 2D vizijskog procesa

Laserske zrake- 3D vizijski proces

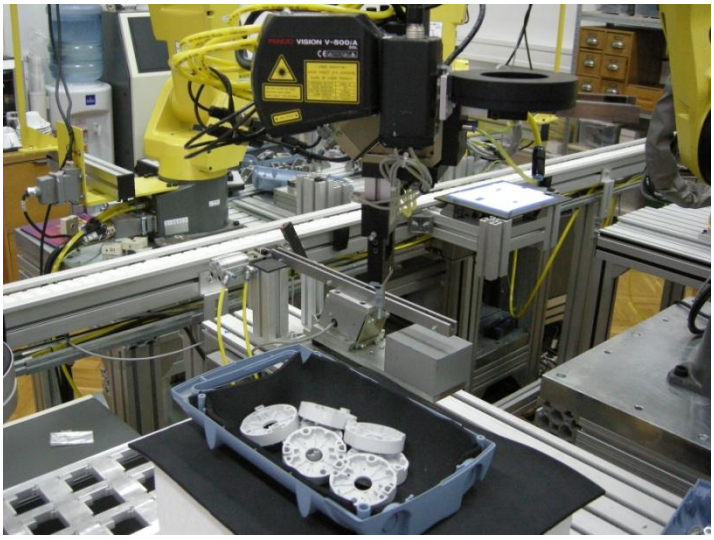

Slika 33: 3D vizijski proces

Točka prilaska

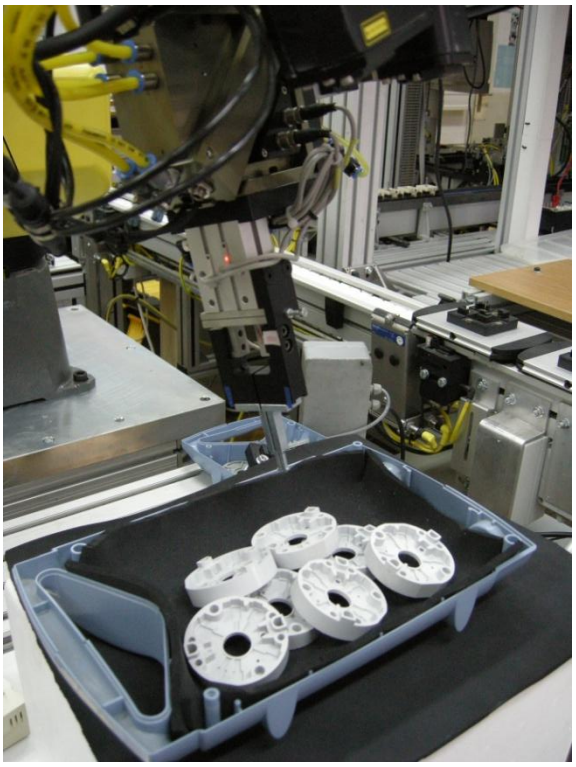

Slika 34: Točka prilaska

Točka hvatanja

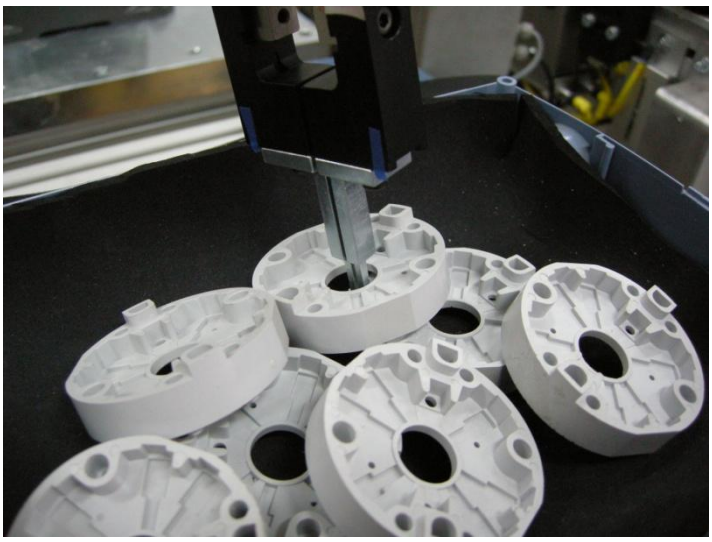

Slika 35: Točka hvatanja

Otvaranje hvataljke

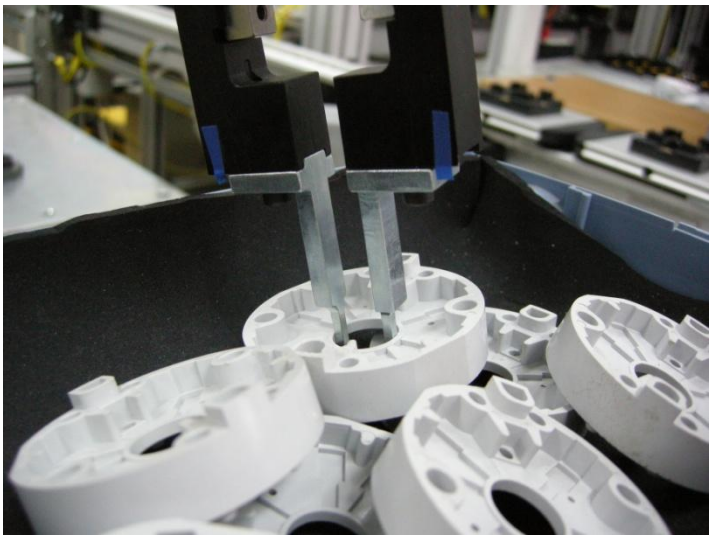

Slika 36: Otvaranje hvataljke

Podizanje predmeta

Slika 37: Podizanje predmeta

Povratak u točku prilaska

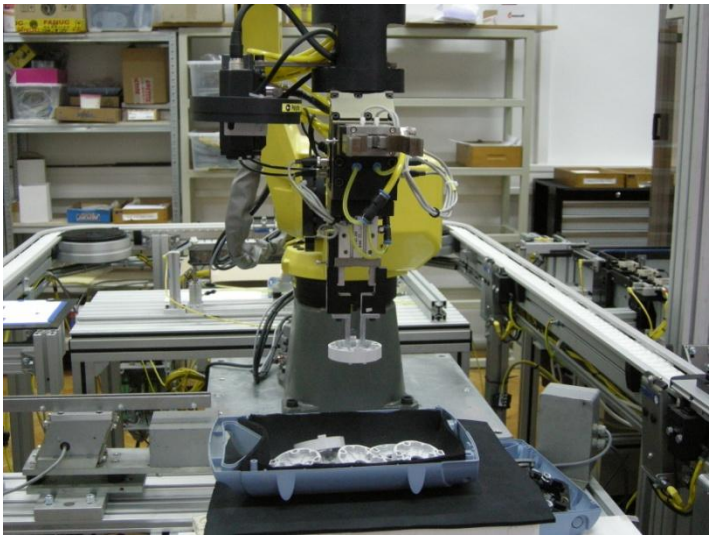

Slika 38: Povratak u točku prilaska

Odvođenje u točku odlaganja

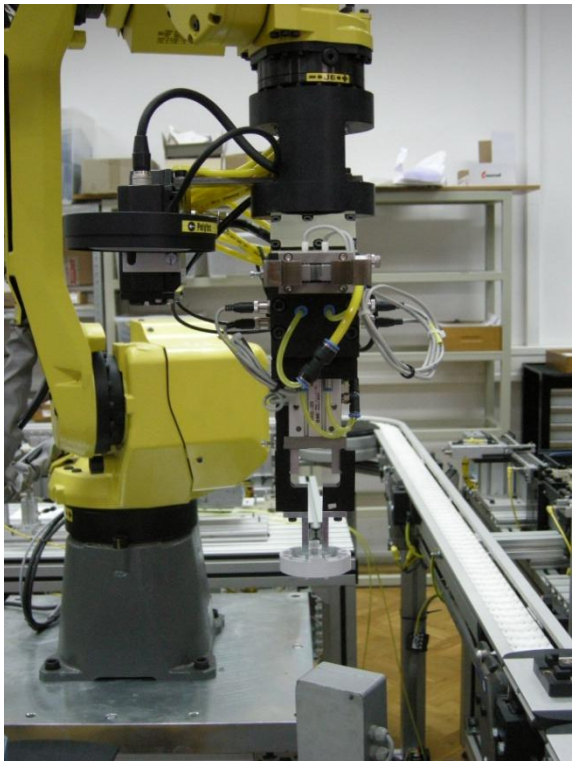

Slika 39: Odvođenje u točku odlaganja

Točka odlaganja

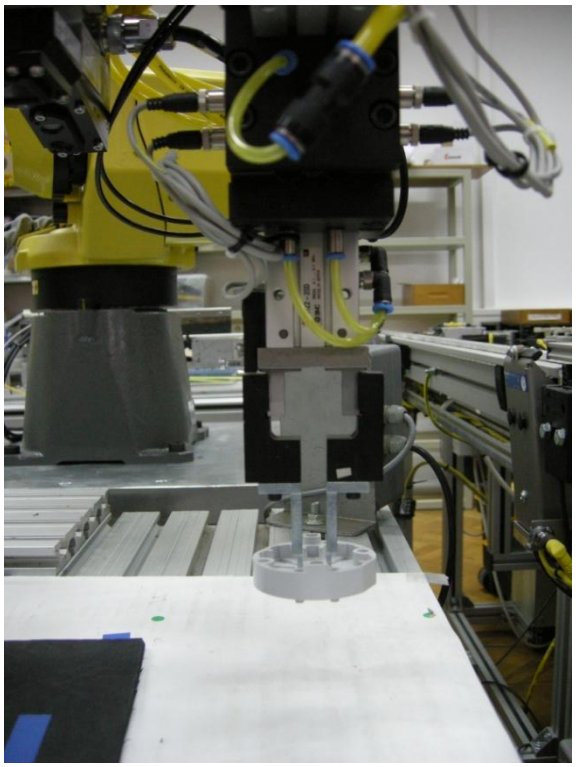

Slika 40: Točka odlaganja

Ispuštanje predmeta

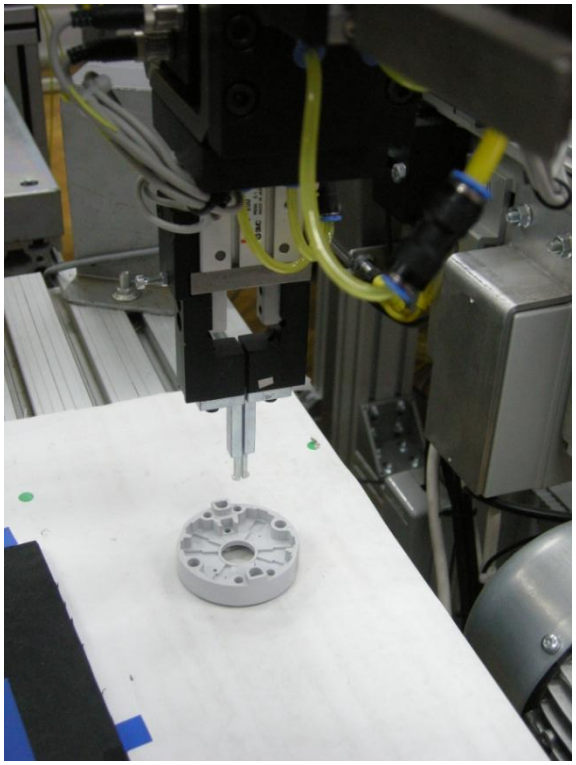

Slika 41: Zatvranje hvataljke

Odlaženej u početnu točku

Slika 42: Odlaženje robotske ruke prema početnoj točki

Povratak u početnu točku

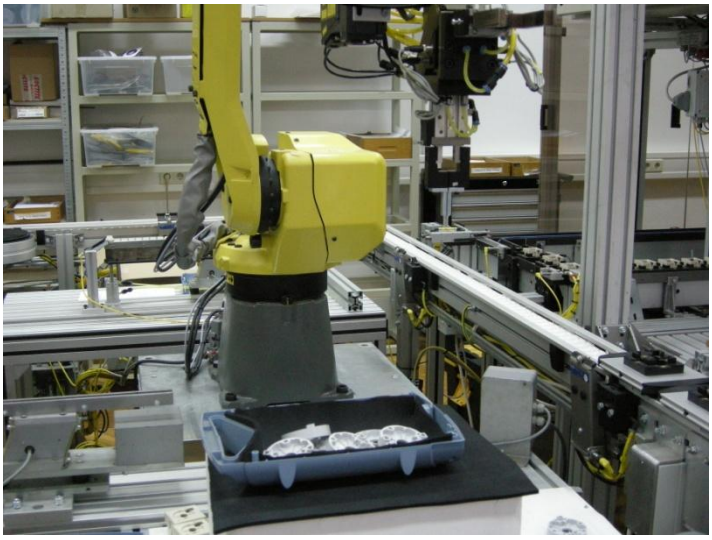

Slika 43: Povratak u početnu točku

7. Zaključak

Pedesetih godina prošlog stoljeća postavljeni su temelji umjetne inteligencije kad su filozofi tog vremena pokušali objasniti proces ljudskog razmišljanja pomoću manipulacije strojnim simbolima. Danas se strojevi, koji mogu „osjetiti“ okolinu u kojoj se nalaze, koriste u različitim područjima, kako tehničkim, tako i znanstvenim. Cilj je stvoriti strojeve, koji će se, učenjem različitih obrazaca, ponašati inteligentno.

U ovom završnom radu bilo je potrebno naučiti robota da, pomoću *i*R Vision 3D laserskog senzora i posebno konstruirane hvataljke, hvata predmete koji su se nalazili u nestrukturiranoj okolini. Proces učenja napravljen je u nekoliko koraka.

Prije svega, bilo je potrebno utvrditi odnos između koordinata na slici i koordinata u realnom svijetu, a to se postiglo kalibracijom kamere i *i*R Vision 3D laserskog senzora.

Nakon toga, slijedio je proces učenja obrasca. Proces učenja bio je podijeljen na dva dijela. U prvom dijelu otkrivao se položaj i orijentacija predmeta, a u drugom i njegov nagib. Učenje se radilo pomoću nekoliko alata (GPM lokacijski alat i 3DL ravninski komandni alat) i to na slijedeći način; bilo je potrebno označiti one značajke koje su se željele vidjeti prilikom prepoznavanja predmeta te one koje su se željele sakriti. Skrivala su se ona područja koja su se i pri maloj promjeni svjetlosnih uvjeta teže prepoznavala. Isto tako, bilo je potrebno dovesti laserske zrake blizu središta predmeta i to tako, da padaju u mjernu ravninu 3DL lasera.

Prilikom učenja obrasca, pojavilo se nekoliko poteškoća, koje su se na neki način morale riješiti, kako bi proces funkcionirao. Jedna od poteškoća koju bih željela istaknuti je osjetljivost kamere na vanjsku svjetlost. Ponekad bi se znalo dogoditi da, zbog promjenjivih vanjskih svjetlosnih uvjeta, vizijskih proces ne radi, tj. kamera ne prepoznaje naučeni obrazac. Taj problem se riješio paljenjem svjetla na početku procesa te podešavanjem vremena ekspozicije kamere.

Nakon učenja obrasca, bilo je potrebno pohraniti referentnu poziciju predmeta.

Na kraju, robotsku se ruku učio položaj predmeta i to na način da ga se dovelo u svaku od karakterističnih točaka (točka slikanja, točka prilaska, točka hvatanja te točka odlaganja). Bitno je naglasiti da se, tijekom učenja karakterističnih točaka, predmeta rada nije pomicao.

Ovaj završni rad pokazuje da *i*R Vision 3D laserski senzor može pridonijeti poboljšanju montažnog procesa posebno u područjima pripreme, orijentacije i pozicioniranja predmeta, s time da se moraju osigurati konstantni svjetlosni uvjeti, kako bi proces bio stabilan.

8. Literatura

[1] Nevatia R., Machine perception, Prentice Hall; Englewood Cliffs, 1982.

[2] Jain R., Kasturi R., Schunck, Machine vision, McGraw- Hill, Singapore, 1995.

[3] Zarevski P., Psihologija pamčenja i učenja, Naklada Slap, Jastrebarsko, 2001.

[4] Jerbić B., Nikolić G., Vranješ B., Kunica Z., Projektiranje automatskih montažnih sustava, Kigen, Zagreb, 2009.

[5] Fanuc Robot series R-30 *i*A/ R-30 *i*A Mate controller *i*R Vision operator's manual, 2009.