Vjerojatnosni model robotskoga djelovanja u fizičkoj interakciji s čovjekom

Šekoranja, Bojan

Doctoral thesis / Disertacija

2015

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:235:434752

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

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

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Bojan Šekoranja

VJEROJATNOSNI MODEL ROBOTSKOGA DJELOVANJA U FIZIČKOJ INTERAKCIJI S ČOVJEKOM

DOKTORSKI RAD

Zagreb, 2015.

Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Bojan Šekoranja

VJEROJATNOSNI MODEL ROBOTSKOGA DJELOVANJA U FIZIČKOJ INTERAKCIJI S ČOVJEKOM

DOKTORSKI RAD

Mentor:
prof. dr. sc. Bojan Jerbić

Zagreb, 2015.

University of Zagreb

FACULTY OF MECHANICAL ENGINEERING
AND NAVAL ARCHITECTURE

Bojan Šekoranja

PROBABILISTIC MODEL OF ROBOT BEHAVIOUR FOR PHYSICAL HUMAN-ROBOT INTERACTION

DOCTORAL THESIS

Supervisor:
prof. dr. sc. Bojan jerbić

Zagreb, 2015.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK: 007.52:519.2:681.5

KLJUČNE RIJEČI: međudjelovanje čovjeka i robota, robotika, taktilni podražaji

ZNANSTVENO PODRUČJE: Tehničke znanosti

ZNANSTVENO POLJE: Strojarstvo

INSTITUCIJA U KOJOJ JE RAD IZRAĐEN: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

MENTOR RADA: Dr.sc. Bojan Jerbić, red. prof.

BROJ STRANICA: 135

BROJ SLIKA: 79

BROJ TABLICA: 23

BROJ KORIŠTENIH BIBLIOGRAFSKIH JEDINICA: 91

DATUM OBRANE: 01.06.2015.

POVJERENSTVO: Dr.sc. Mladen Crneković, red. prof. – predsjednik
(Fakultet strojarstva i brodogradnje, Zagreb)

Dr.sc. Bojan Jerbić, red. prof. – mentor
(Fakultet strojarstva i brodogradnje, Zagreb)

Dr.sc. Stjepan Bogdan, red. prof. – član
(Fakultet elektrotehnike i računarstva, Zagreb)

INSTITUCIJA U KOJOJ JE RAD POHRANJEN: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

PODACI O MENTORU

Bojan Jerbić rođen je 13. rujna 1957. godine u Zagrebu. Osnovnu školu i Matematičku gimnaziju pohađao je u Zagrebu. Na Fakultet strojarstva i brodogradnje, Sveučilišta u Zagrebu upisao se 1976 godine. Diplomirao je 25. veljače 1983. godine diplomskim radom: "Kinematička struktura Stanford manipulatora".

Poslijediplomski studij pohađao je u razdoblju od 1984. do 1987. godine na FSB-u, smjer Tehnologija u strojarskoj proizvodnji, Projektiranje proizvodnih procesa. Magistarski rad pod naslovom "Istraživanje optimalnog redoslijeda sredstava za proizvodnju", obranio je 1987. godine te stekao naslov magistra tehničkih znanosti.

Kao stipendista Florida State University boravi tijekom 1989. godine šest mjeseci na Department of Industrial Engineering, provodeći istraživanja u okviru izrade disertacije i znanstveno-stručnog usavršavanja. Disertaciju pod naslovom: "Interpretacija geometrije CAD modela u projektiranju automatske montaže ekspertnim sustavom", obranio je 1993. godine na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu, te stekao naslov doktora tehničkih znanosti iz znanstvenog područja Strojarstvo.

Od 1984. godine radi na Katedri za projektiranje proizvodnih procesa, Zavoda za tehnologiju, FSB-a, prvo kao pripravnik, a zatim kao stručni suradnik sve do 1986. godine, kada je izabran za asistenta. U zvanje znanstvenog asistenta izabran je 1988. godine. Zvanje docenta stekao je 1995. godine, izvanrednog profesora 2000. godine, a zvanje redovitog profesora 2005. godine. Od 1993. do 2006. godine voditelj je Laboratorija za projektiranje izradbenih i montažnih sustava. Dužnost predstojnika Zavoda za robotiku i automatizaciju proizvodnih sustava obnašao je od 2005. do 2008. godine. Na mjestu voditelja Katedre za projektiranje izradbenih i montažnih sustava je od 2007. godine do danas.

Sudjeluje u izvođenju nastave iz predmeta: Automati za montažu, Projektiranje automatskih montažnih sustava, Umjetna inteligencija, Računalne mreže, Virtualno oblikovanje mehatroničkih sustava, Istodobno inženjerstvo, Programiranje automata za montažu, Vizijski sustavi, Inteligentni montažni sustavi i Integrirano inženjerstvo. Uveo je u nastavu brojne nove sadržaje, od primjene inženjerskih računalnih metoda u projektiranju do primijenjene robotike i umjetne inteligencije.

U znanstvenom radu posvetio se projektiranju izradbenih i montažnih sustava, poglavito razvoju računalnih metoda u projektiranju i metoda umjetne inteligencije u robotskoj montaži. U organiziranom znanstvenoistraživačkom radu sudjeluje od 1987. godine i autor je više od

stotinu znanstvenih i stručnih radova. Bio je suradnik na sedam znanstvenih projekata te voditelj osam domaćih i međunarodnih znanstvenih i tehnologijskih projekata.

Osim u nastavnim i istraživačkim, aktivno sudjeluje u ostalim aktivnostima Fakulteta doprinoseći ukupnom razvoju znanstvenonastavnih djelatnosti. Od 1990. do 2006. godine član je Odbora za informatizaciju i kompjutorizaciju Fakulteta, a od 1997. godine djelovođa i potom član Povjerenstva za diplomske ispite Proizvodnog smjera, sve do 2010. Od 2009. do 2010. godine član je Odbora za poslijediplomske studije. Funkciju predsjednika Odbora za strategiju Fakulteta obnaša od 2010. do 2012. godine.

Tijekom svoje karijere kontinuirano je radio na popularizaciji struke putem brojnih javnih nastupa u medijima te objavljujući mnoge popularizacijske članke. Održao je 28 pozvanih predavanja u zemlji i inozemstvu.

Zahvaljujem se svom mentoru prof.dr.sc. Bojanu Jerbiću na savjetima i pomoći tijekom istraživanja i pisanja rada.

Zahvaljujem članovima povjerenstva, prof. dr. sc. Mladenu Crnekoviću i prof. dr. sc. Stjepanu Bogdanu, za pronalaženje vremena za pregled ovog rada, te za sve komentare i primjedbe koje su poboljšale njegovu kvalitetu.

Zahvaljujem svim dragim prijateljima koji su mi bili spremni pomoći u brojnim malim i velikim stvarima i bili uvijek uz mene.

Na kraju, najveću zahvalnost dugujem svojoj obitelji i djevojci na beskrajnoj podršci i razumijevanju.

Sažetak

U doktorskom radu razvijen je vjerojatnosni model pomoću kojeg robot donosi odluke o svojem djelovanju putem fizičke interakcije s čovjekom. Klasifikacijom taktilnih podražaja na temelju kapacitivnog senzora, sile i prostornog položaja razaznaju se elementi i smisao interakcije. Kako bi model imao određenu autonomiju i mogućnost kretanja kroz prostor u sklopu istraživanja obrađen je problem prostornog kretanja. U sklopu istraživanja definirana je višekriterijska interpretacija radnog prostora u kojoj postoji distinkcija između objekata u okolini, čovjeka, ciljeva, samog robota te putanja robota. Model interakcije je oblikovan kao slijed radnji koje robot izvršava što u konačnici rezultira robotskim djelovanjem. Definiranje varijabli vjerojatnosti modela proizlazi iz interakcije s čovjekom. Naučeni obrasci predstavljaju dugoročno znanje na temelju kojih se oblikuje robotsko djelovanje u skladu s trenutnim stanjem okoline. Vremenskim razlikovanjem bližim događajima pridaje se značajno veći faktor utjecaja, a onim udaljenijim u prošlost mnogo manji. U laboratorijskim uvjetima provedeni su pokusi na realnom sustavu koji čine robotska ruka s integriranim senzorima momenata i upravljačkom jedinicom, računalo, kao i „umjetna koža“ koja posjeduje mogućnost razlučivanja ljudskog dodira i neposredne blizine prvenstveno biološkog materijala. Eksperimentima su utvrđena ograničenja primjene autonomnog djelovanja robota.

Extended summary

More and more tasks are aided by technological solutions. Limitations of technical systems, in most cases, result with a person supporting the system during its operation. A person is dislocated from the work area and uses robots as tools. Development of interactive models could change this paradigm by placing a person at the centre with support and assistance provided by the robot as a partner.

So far, for security reasons, robots and people worked strictly separate, but development can enable joint working areas, which can be beneficial. In such environments a contact between robots and humans can occur, and the question of the physical interaction becomes an important issue. The issue of contact with humans so far was seen as a binary problem where if a person came to contact the robot stopped, otherwise his action wasn't interrupted. The thesis proposes the use of new technologies and interaction models based on physical interaction, enabling humans and robots to work and perform interaction in shared working areas. To make this acceptable for the user the interaction must be intuitive. The robot must be able to perform movements and tasks at the request of users, know the workspace and take operator safety into account.

The proposed model determines robot's activities through physical interaction with humans. Classification of tactile stimuli, registered using capacitive sensors, force and spatial position, distinguishes the elements and the meaning of interaction. In order to provide a certain autonomy and the possibility of moving through space the process of motion planning was integrated in the model. As part of the research a multiple criteria interpretation of the working area, in which there is a distinction between objects in the environment, human, goals, the robot and the robot path, is defined. The model of interaction is formed by a sequence of actions that the robot executes which ultimately results in robotic action. Defining the probability of the model variables results from the interaction with humans. Learned patterns are stored as long-term knowledge based on which the robotic action, in accordance with the current state of the environment, is formed. Temporal difference assigns a significantly higher probability factor to more recent events, and to those more distant in time much smaller.

This thesis is organized in six chapters, as follows:

Chapter 1: *Introduction.* This chapter presents the advantages and limitations of robotic technology. Senses and perception, along with sign language and tactile interaction are

described. With the development of technology tactile language and tactile interaction are applied in interfaces with technology. Since the work is based on physical interaction the importance and benefits of touch are emphasized.

Chapter 2: *Human robot interaction.* After introductory remarks there is a summed overview of human robot interaction. The basic user interfaces are described and the relevance of the research is presented. Also the chapter reviews the literature related to the topic of the thesis and explains the research scope. The interaction model, which will recognize the intent and message of a person and in accordance with them to achieve desired behaviour, is explained.

Chapter 3: *Tactile stimuli classification*. The third chapter deals with the interpretation of the physical interaction. A description of the system components, hardware and software, which can react to tactile stimuli is given. The classification model, which is divided into several categories, is described. Multiple criteria interpretation of space, with different layers and time components, based on which the running planning movement in the configuration space is explained in detail. Experiments that are used to define the parameters of classification, such as speed, displacement, and force, are shown at the end of the chapter.

Chapter 4: *Probabilistic model*. The chapter presents a probabilistic model. Concepts necessary for describing the model, theoretical basis of probability and Markov processes that form the basis of the model are introduced and defined. The model is based on the multiple criteria workspace definition, the stochastic chain status and experiential knowledge with time differentiation of events. The experiment deals with the problem complexity and size of the probability transition matrix.

Chapter 5: *Experimental results*. This chapter deals with the validation and verification of the proposed methodology. Simulations and experiments are conducted to test the safety and efficacy of the developed algorithms and classification. Experiments were carried out in laboratory conditions using lightweight robot arm and capacitive sensors ("artificial skin").

Chapter 6: *Conclusion*. This chapter summarises the main contributions of the dissertation and presents several recommendations for future research.

Ključne riječi (Keywords)

Ključne riječi:

- međudjelovanje čovjeka i robota
- robotika
- taktilni podražaji

Keywords:

- human-robot interaction
- robotics
- physical interaction

Sadržaj

Sažetak I

Extended summary II

Ključne riječi (Keywords) IV

Sadržaj V

Popis slika VIII

Popis tablica XI

Popis važnijih oznaka XII

1. Uvod 1

1.1. Osjetila i percepcija 4

1.2. Taktilna interakcija 7

1.3. Struktura rada 9

2. Interakcija čovjeka i robota 11

2.1. Korisnička sučelja – od HCI do HRI 13

2.2. Pregled dosadašnjih istraživanja 16

2.3. Predloženi model interakcije 22

3. Tumačenje fizičke interakcije 26

3.1. Hardver i softver 27

3.1.1. Kapacitivni senzor 28

3.1.2. Robot 30

3.2. Klasifikacija taktilnog podražaja 32

3.2.1. Opažanje sudara 33

3.2.2. Aktivni kontakt 35

3.2.3. Radne operacije 43

3.3. Višekriterijska interpretacija prostora 45

3.3.1. Slojevi višekriterijske interpretacije prostora 46

3.3.2. Vremenska komponenta i preklapanje slojeva 50

3.3.3. Konfiguracijski prostor ... 53
3.3.4. Prostorno planiranje ... 54
3.4. Eksperiment ... 61
3.4.1. Eksperimentalno definiranje parametara klasifikacije brzine ... 61
3.4.2. Eksperimentalno definiranje parametara klasifikacije smjera pomaka ... 69
3.4.3. Eksperimentalno definiranje parametara klasifikacije sile ... 71
4. Vjerojatnosni model ... 73
4.1. Teorijska osnova ... 74
4.1.1. Vjerojatnost ... 74
4.1.2. Uvjetna vjerojatnost ... 74
4.1.3. Stohastički procesi ... 75
4.1.4. Markovljevi lanci ... 76
4.1.5. Prijelazne vjerojatnosti ... 78
4.2. Model ... 79
4.2.1. Oblikovanje matrice prijelaznih vrijednosti ... 81
4.2.2. Vremensko razlikovanje ... 83
4.2.3. Prostorni utjecaj ... 86
4.3. Eksperiment ... 87
4.3.1. Kompleksnost prijelaznih matrica ... 88
4.3.2. Slučajne vrijednosti ... 90
4.3.3. Broj uzastopnih ponavljanja u slučajnim lancima ... 95
4.3.4. Iskoristivost lanaca ... 96
5. Eksperimentalna validacija ... 99
5.1. Validacija tumačenja taktilne interakcije ... 100
5.2. Oblikovanje slijeda djelovanja ... 104
5.3. Autonomno djelovanje ... 111
5.3.1. Slobodan radni prostor ... 114

5.3.2. Zauzetost radnog prostora 115

6. Zaključak 119

6.1. Znanstveni doprinos rada 122

6.2. Smjerovi daljnjeg istraživanja 123

7. Literatura 124

Životopis 132

Biography 133

Popis radova 134

Popis slika

Slika 1.1. Ilya Repin: „Burlaci na Volgi“. 1
Slika 1.2. Skup sposobnosti. 2
Slika 1.3. Marty Neumier – Robotska krivulja [3]. 4
Slika 1.4. Percepcija i osjetila. 5
Slika 1.5. Taktilna znakovna abeceda [12]. 8
Slika 2.1. Transformacije koordinatnih sustava robota. 13
Slika 2.2. Ulazno-izlazne jedinice. 14
Slika 2.3. Upravljačka konzola. 15
Slika 2.4. Kuka robotska ruka – LWR4+ (lightweight robot). 16
Slika 2.5. Taktilni senzor [45]. 18
Slika 2.6. Optimizacija putanje kretanja [67]. 20
Slika 2.7. Putanja u prisutnosti čovjeka [71]. 21
Slika 2.8. Predloženi model interakcije. 25
Slika 3.1. Prikaz sustava. 27
Slika 3.2. Kapacitivni senzor. 28
Slika 3.3. Robotska ruka s elektrodama kapacitivnog senzora. 30
Slika 3.4. FRI sučelje [34]. 31
Slika 3.5. Točka središta alata. 37
Slika 3.6. Segmentacija na osnovi brzine. 37
Slika 3.7. Vremenski razmak između dvaju segmenata: a) kratki interval, b) dugi interval. 40
Slika 3.8. Gesta odlaganja. 41
Slika 3.9. Smjer korisnika i cilja. 42
Slika 3.10. Umetanje osovine. 44
Slika 3.11. Sile uslijed bušenja kosti kirurškom bušilicom. 44
Slika 3.12. Radni prostor W_S. 46
Slika 3.13. Prostor ciljeva. 47
Slika 3.14. Prostor prepreka. 48
Slika 3.15. Prostor sudara s ljudima. 49
Slika 3.16. Prostor putanja. 50
Slika 3.17. Kratkoročno pamćenje – zaboravljanje [81]. 51
Slika 3.18. Linearna karakteristika funkcija smanjenja intenziteta. 52
Slika 3.19. Preklapanje slojeva. 52

Slika 3.20. Prikaz u Kartezijevu a) i konfiguracijskom b) koordinatnom sustavu..... 54
Slika 3.21. Diskretizacija prostora: a) 15 x 50, b) 30 x 100, c) 60 x 200..... 56
Slika 3.22. Mogući smjerovi kretanja: a) četiri smjera, b) osam smjerova..... 58
Slika 3.23. Putanja a) u četiri smjera kretanja, b) osam smjerova kretanja. 58
Slika 3.24. Planirana putanja u konfiguracijskom prostoru – različiti pragovi: a) stvarne vrijednosti, b) planiranje pri visokoj sigurnosti, c) planiranje pri srednjoj sigurnosti, d) planiranje pri vrlo niskoj sigurnosti. 60
Slika 3.25. Putanje spore a) i brze b) kretnje. 62
Slika 3.26. Usporedba brzine kratke brze a) i duge spore b) kretnje. 63
Slika 3.27. Usporedba raspona a) prosječnih i b) maksimalnih brzina na uzorku. 64
Slika 3.28. Usporedba brzina i sila a) duge spore, b) kratke brze, c) duge brze kretnje i d) trzaja. 65
Slika 3.29. Usporedba raspona a) prosječnih i b) maksimalnih sila na uzorku..... 66
Slika 3.30. Dvokriterijski modeli klasifikacije..... 67
Slika 3.31. Dvokriterijski model klasifikacije brzine pokreta na temelju prosječnih i maksimalnih sila..... 68
Slika 3.32. Klasifikacija parametara pomaka – usporedba ovisnosti odstupanja s obzirom na udaljenost. 71
Slika 3.33. Raspon maksimalnih sila po skupinama uzorka. 72
Slika 4.1. Stohastički procesi: a) Poissonov proces, b) Brownovo gibanje. 76
Slika 4.2. Markovljev lanac prvog reda. 77
Slika 4.3. Markovljev lanac drugog reda. 77
Slika 4.4. Markovljev lanac k-tog reda. 77
Slika 4.5. Markovljev lanac s tri stanja. 79
Slika 4.6. Razine programiranja [86]. 80
Slika 4.7. Lanac stanja..... 80
Slika 4.8. Sekvence t-1 i t-2. 82
Slika 4.9. Važnost događaja protjecanjem vremena. 84
Slika 4.10. Učenje podrškom [89]..... 84
Slika 4.11. Funkcija vremenskog razlikovanja s obzirom na vrijednost baze λ. 85
Slika 4.12. Distribucija slučajnih varijabli za deset stanja. 91
Slika 4.13. Distribucija slučajnih varijabli za trideset stanja. 92
Slika 4.14. Razdioba dužine lanaca za deset stanja..... 94
Slika 4.15. Razdioba dužine lanaca za trideset stanja. 94

Slika 4.16. Vjerojatnost događaja uzastopnih ponavljanja. 95
Slika 4.17. Iskoristivost različitih redova Markovljeva lanca. 97
Slika 5.1. Oprema korištena pri provedbi eksperimenata. 100
Slika 5.2. Eksperiment klasifikacije brzine na temelju ostvarenih kretnji. 102
Slika 5.3. Putanja geste BD - KT – BG. 103
Slika 5.4. Segmenti pokreta geste BD – KT – BG. 103
Slika 5.5. Parametri pokreta geste BD – KT – BG po komponentama. 104
Slika 5.6. Izuzimanje i odlaganje predmeta. 105
Slika 5.7. Oblikovanja slijeda djelovanja fizičkom interakcijom. 106
Slika 5.8. Oblikovane putanje. 107
Slika 5.9. Segmenti pokreta. 107
Slika 5.10. Parametri pokreta po komponentama. 108
Slika 5.11. Segmenti sile u stacionarnim stanjima. 110
Slika 5.12. Komponente sile. 110
Slika 5.13. Lanac stanja eksperimenta. 111
Slika 5.14. Oblikovanje obrasca djelovanja. 112
Slika 5.15. Radni prostor: a) slobodan, b) s čovjekom u radnom području. 114
Slika 5.16. Eksperiment sa zauzetosti radnog prostora. 117

Popis tablica

Tablica 1.1. Protok informacija osjetilnog sustava [6]. 6
Tablica 3.1. Klasifikacija sudara. 34
Tablica 3.2. Osnovne kretnje. 38
Tablica 3.3. Osnovne sile. 39
Tablica 3.4. Tablica osnovnih gesti. 41
Tablica 3.5. Diskretizacija kuta. 55
Tablica 3.6. Diskretizacija radijusa. 55
Tablica 3.7. Dvokriterijska klasifikacija brzine pokreta na temelju prosječnih i maksimalnih sila. 69
Tablica 4.1. Podjela stohastičkih procesa. 76
Tablica 4.2. Prijelazna matrica prvog reda za pet stanja. 89
Tablica 4.3. Prijelazna matrica trećeg reda za pet stanja. 89
Tablica 4.4. Ukupan broj vrijednosti prijelazne matrice s obzirom na red procesa i broj stanja. 90
Tablica 4.5. Relativne frekvencije za 10 stanja. 90
Tablica 4.6. Relativne frekvencije za 30 stanja. 92
Tablica 4.7. Razdioba dužine nizova. 93
Tablica 4.8. Vjerojatnost događaja uzastopnih ponavljanja. 95
Tablica 4.9. Iskoristivost i vrijeme obrade različitih redova Markovljeva lanca. 97
Tablica 5.1. Rezultat klasifikacije brzine na temelju kretnje korisnika. 101
Tablica 5.2. Razlučene geste segmenata pokreta na temelju parametara. 109
Tablica 5.3. Razlučene geste u stacionarnim stanjima. 110
Tablica 5.4. Eksperiment – vrijednosti Psx u ovisnosti o λ. 115
Tablica 5.5. Eksperiment: $\lambda \in 0{,}1$, $pd = 0$. 116
Tablica 5.6. Eksperiment: $\lambda = 0{,}9$, $pd = 0{,}25$. 116

Popis važnijih oznaka

Oznaka	**Opis**	**Jedinica**
Grčke oznake:		
$\boldsymbol{\tau}$	vektor momenata	
θ	kut između segmenta robotske ruke i apscise	rad
ω	elementarni događaj	
Ω	prostor elementarnih događaja	
λ	baza eksponenta vremenskog otežavanja	
Latinske oznake:		
t	vrijeme	s
v	brzina	m/s
x	vrijednost funkcije na apscisi	
y	vrijednost funkcije na ordinati	
d	udaljenost	mm
s	put	mm
$\boldsymbol{F}$	vektor sila	
$\mathbb{R}$	skup realnih brojeva	
W	radni prostor	
C	konfiguracijski prostor	
W_S	ograničen radni prostor	
P_C	prostor ciljeva	
P_O	prostor prepreka	
P_L	prostor sudara s ljudima	
P_T	prostor putanja	
P_{VK}	višekriterijska interpretacija prostora	
r	radijus	mm
X	slučajna varijabla stohastičkog (slučajnog) procesa	
T	skup vremena	
S	skup stanja	
s	stanje	
P	matrica prijelaznih vjerojatnosti	
p_{ij}	prijelazna vjerojatnost	
D	matrica dostupnosti	
d_{ij}	vjerojatnost prostorne kretnje	

$f(x)$	funkcija gustoće vjerojatnosti
M	matrica modela

1. Uvod

Razvoj tehnologije nesumnjivo mijenja naš način života i općenito pridonosi kvaliteti života. Mijenjaju se zadaci i olakšava se ljudsko djelovanje. U povijesti nalazimo brojne primjere utjecaja tehnologije na ljudsko društvo i zamjene ljudskog rada strojevima. Takvi se motivi provlače kroz povijesne zapise, ali i kroz umjetnost.

Slika 1.1. *Ilya Repin: „Burlaci na Volgi“.*

Jedan primjer je rad ljudi koji vuku barku na rijeci Volgi, prikazan na jednoj od najpoznatijih slika ruske umjetnosti (*Slika 1.1*), koja prikazuje nehumane radne uvjete i teškoće. No u pozadini slike nazire se parobrod – slika suptilno govori da postoji i drugi način. Nedugo nakon nastanka slike ljudi su zamijenjeni tegljačima brodova na parni pogon.

Posebice danas, svi smo svjesni značajnog tehnološkog napretka na svim područjima. Strojevi su sve sposobniji. Sve je više zadataka potpomognuto tehnološkim rješenjima. Automatizacija je prvi oblik primjene tehnologije koja u potpunosti zamjenjuje ljudski rad. Automatski sustavi mogu preuzeti zadatke koje su obavljali ljudi, bilo daje riječ o regulaciji, automatskom vođenju ili nekom drugom zadatku. Zato postoji tendencija da ljudi vjeruju da će mnogi problemi u koje je uključen ljudski faktor greške. Također tehnologija spašava ljude od

dosadnih rutinskih zadataka, dopuštajući produktivnije korištenje vremenom, te smanjuje umor i pogreške. U isto vrijeme sustavi postaju složeniji te se tako povećavaju teškoće pri uporabi i frustracije s tehnologijom. Problem dizajna sučelja koje postavlja tehnološki napredak je ogroman. Ista tehnologija koja pojednostavljuje život pružajući više funkcija u svakom uređaju istodobno komplicira život tako što je uređaj teže upotrebljavati. To je paradoks tehnologije i izazov za oblikovanje jednostavnih sučelja i pristupa [1].

Računala postaju mobilna i sveprisutna. Jedno je softversko zamjenjivanje ljudskog rada, no da bismo zamijenili fizičku komponentu, uvodimo robotske tehnologije. Robotska tehnologija je dosegla razinu koja otvara nove mogućnosti i nove primjene. Robotika se sve više prilagođava za rad u ljudskoj okolini, koja sa svojim dinamičnim promjena i nestrukturiranošću donosi nove izazove. Robotski manipulatori su sve prisutniji u industrijskom okruženju zbog svojih radnih sposobnosti koje odlikuje prije svega preciznost, ponovljivost i brzina. U ekonomskom smislu, to se odražava na veću proizvodnost te niže troškove proizvodnje. U većini slučajeva primjenjuju se u operacijama sklapanja, gdje su sve komponente uvijek u istom položaju i proces se periodički ponavlja. Zbog ograničene sposobnosti prilagođavanja na promjene u svojoj okolini roboti su najčešće izolirani od ljudi iz sigurnosnih razloga. Međutim, razvoj suvremenih tehnologija u području senzorike, vizijskih sustava i naprednih metoda upravljanja otvara mogućnost primjene robota u potpuno novim zadaćama, poglavito u ostvarivanju suradnje s ljudima. S povećanjem stupnja složenosti zadataka neki zadaci nadilaze domenu pojedinačnih sposobnosti čovjeka i robota. Kod trivijalnih zadataka koje svaki od njih može izvesti samostalno da ne nadilaze sposobnosti čovjeka ni robota rješenje problema mnogo je jednostavnije. Problem prelazi na višu razinu kada ni čovjek ni robot nemaju adekvatne sposobnosti da odrade zadatak samostalno te je potrebna interakcija. Interakcijom se omogućuje zalaženje jedne domene u drugu, a time i povećanje skupa sposobnosti.

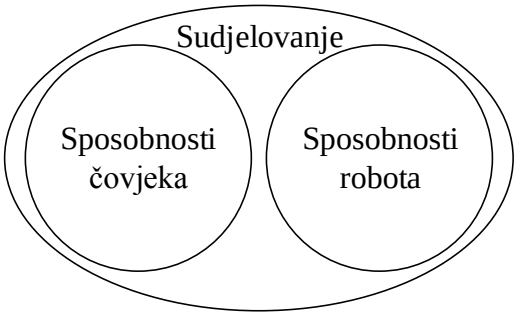

Slika 1.2. *Skup sposobnosti.*

Prednost robotske tehnologije je što ne podliježe određenim ljudskim „slabostima”. Strojevi nisu emocionalni, ne podliježu umoru i promjenama raspoloženja koje utječu na produktivnost te na njih ne utječu informacije irelevantne za trenutno djelovanje. Provode zadane zadaće brzo, efikasno i kvalitetno. No potreba za vještinama koje izričito posjeduju ljudi javlja se uslijed raznovrsnih ograničenja. Robotska tehnologija je još uvijek „primitivna” – roboti vrlo dobro mogu raditi zadatke koji se ponavljaju uz većinom striktno definiranu okolinu, ali njihova efikasnost pokazuje svoju krhku stranu ako dolazi do promjena u sustavu ili okolini. Neke od prednosti čovjeka nad robotom su prilagodljivost, visoka razina znanja i vještina te inovativnost. Kako čovjek povećava količinu dostupnih znanja s razvojem i dostupnošću svih informacija u svakom trenutku (uz pomoć interneta i razvoja informacijskih tehnologija), tako postoji mogućnost da proširi i rang svojih sposobnosti upotrebom podrške upravo robotskih asistenata. Ljudi još uvijek daleko nadilaze sposobnosti tumačenja i primjenjivanja znanja s obzirom na kontekstualno znanje u usporedbi s računalima, i tu leži čovjekova prednost.

Ljudi su inteligentni, kreativni i sposobni prilagođavati se najrazličitijim situacijama. Strojevi su snažni, brzi, precizni, ali često ograničeni na oblik djelovanja za koje su zamišljeni. Takva razlika može dovesti do proširenja mogućnosti ako se pravilno upotrijebi. No problemi nastaju kada zajedničko djelovanje ne primjenjujemo kao oblik suradnje. Primjerice kada delegiramo strojevima sve zadatke koje mogu obavljati, a ljudima prepustimo preostale zadaće. To vodi do zahtjeva da se ljudi ponašaju i djeluju kao strojevi kako bi ih mogli pratiti. Zahtijevamo od ljudi da nadziru strojeve u duljem periodu, obavljaju zadaće koje se ponavljaju s visokom točnošću koju zahtijevaju strojevi, u čemu su ljudi loši u duljem periodu. Kada na taj način podijelimo zadatke, ne možemo iskoristiti ljudske prednosti i sposobnosti.

Simbiozom sposobnosti otvara se čitav spektar novih mogućnosti djelovanja s upotrebom prednosti obaju izvršitelja. Hibridni sustavi u kojima ljudi i roboti surađuju omogućavaju ljudima iskorištavanje robotske brzine i preciznosti, istodobno dopunjavajući ograničene kognitivne sposobnosti robota. Brynjolfsson i McAfee [2] smatraju da je najbolje rješenje upravo suradnja: „Ključ za pobjedu je da se ne natječemo protiv strojeva, već da se natječemo sa strojevima. Srećom, ljudi su najjači upravo tamo gdje su računala slaba, što stvara potencijalno uspješno partnerstvo”. Takav spoj vještina omogućava rad čovjeka na višim instancama složenosti poslova te delegiranje fizički zahtjevnijeg, ali i manje kognitivno zahtjevnog rada robotskom asistentu. U aspektima rada koji zahtijevaju niske razine znanja i vještina roboti dominiraju te razvojem tehnologije sve više zamjenjuju ljude u područjima

takvog djelovanja. Nove tehnologije donose kaskadno slijevanje sve većeg broja domena ljudskog djelovanja u neki oblik automatskog izvođenja (*Slika 1.3*). Kako rad postaje automatiziran, njegova se vrijednost smanjuje. Zahvaljujući automatizaciji, kreativni rad na kraju postane stručni rad, koji na kraju postaje rutinski rad, što se u konačnici pretvara u robotski rad [3]. Na svakom koraku puta stvaraju se nove vrijednosti i u konačnici se zamjenjuju ljudi u monotonim, repetitivnim i napornim poslovima.

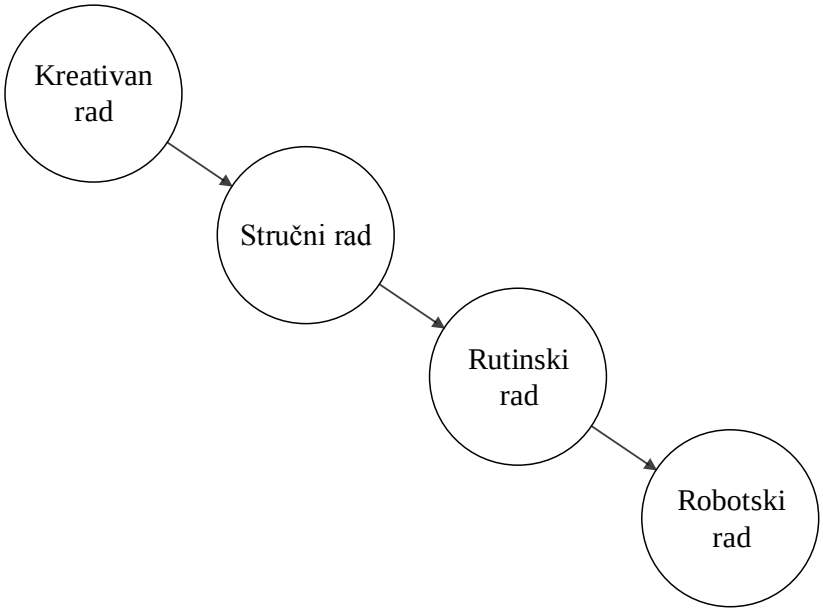

Slika 1.3. *Marty Neumier – Robotska krivulja [3].*

1.1. Osjetila i percepcija

Pojmovi osjetila i percepcija upotrebljavaju se svakodnevno, no iako su usko vezani, postoji jasna distinkcija između tih dvaju pojmova. Informacije iz okoline čovjek prima pomoću svojih osjetila: vida, sluha, dodira, okusa, njuha, osjeta hladnoće i topline, boli te kinestetičkih osjetila (*Slika 1.4*). Proces organizacije i interpretacije informacija prikupljenih od osjetila u vidu razumijevanja okoline nazivamo percepcijom. Percepcija se oblikuje učenjem, pamćenjem i očekivanjima. Iako svjesno percipiramo tek jedan dio količine informacija, naša osjetila prenose velike količine podataka.

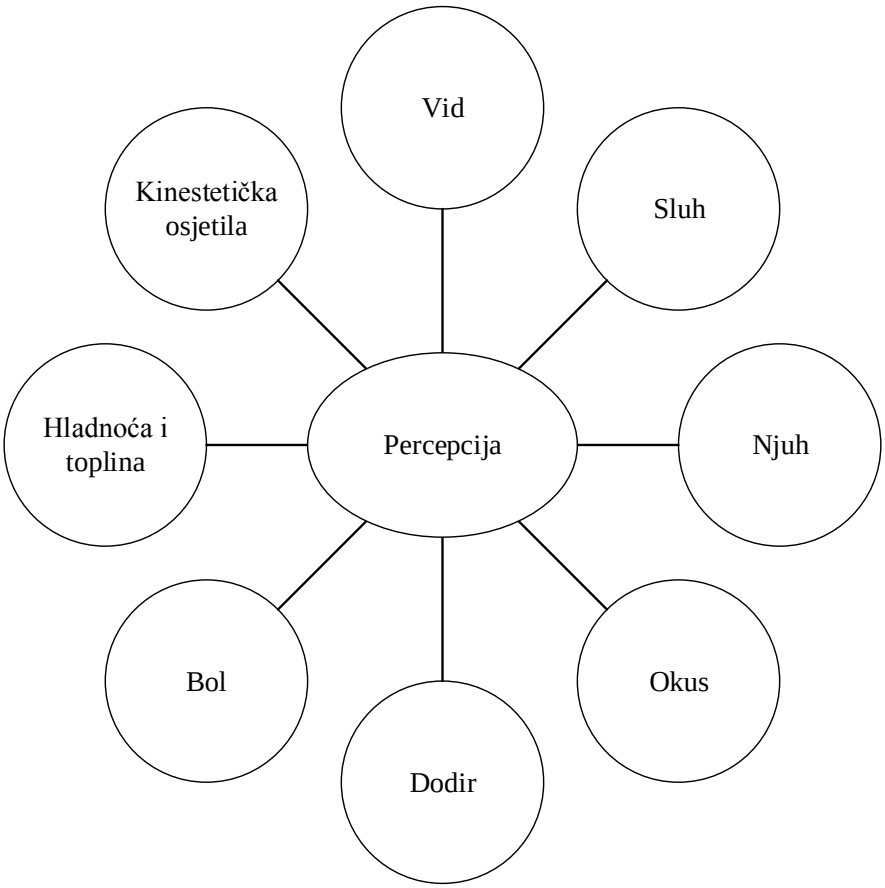

Slika 1.4. *Percepcija i osjetila.*

Da bi robot mogao raditi samostalno, bez obzira na razinu samostalnosti, mora percipirati sebe i svoju okolinu. Robot mora imati mogućnost mjerenja vlastitog položaja i brzine, kao i različitih veličina u radnoj okolini, čime stječe spoznaju o prostoru. Različiti mjerni uređaji i sustavi kojima robot prima informacije nazivaju se senzori. Kao razuman slijed, inspiraciju za razvoj senzora crpimo iz ljudske percepcije, tako da je logično rješenje kopirati ljudski senzorski sustav. Naravno, naš je senzorski sustav previše sofisticiran da bismo ga mogli jednostavno replicirati, no težimo tome u svim oblicima. Primjerice robotska ruka, slično kao i ljudska, ima dvije usko vezane funkcije – kao izvršni i perceptivni organ. Izvršna funkcija je provođenje raznih djelovanja, dok je zadaća perceptivnog dijela traženje i procesiranje informacija o okolini. Te dvije funkcije usko su vezane. Tako kada je glavna zadaća izvršavanje praktičnog djelovanja, percepcija omogućava izvršavanje tog zadatka, a dok je primarno djelovanje kao percepcijski sustav, tada je motorika podređena pretraživanju prostora i traženju informacija iz okoline [4].

Ne ulazeći u sve oblike percepcije i osjetila te njihovih prednosti i nedostataka, zadržat ćemo se samo na dvoma na koje će se interakcija u ovom radu oslanjati – dodiru i kinestetičkim osjetilima.

Jedna vrsta percepcije kojom će se ovaj rad baviti je interakcija dodirom. Dodir ima važnost u svakodnevnim socijalnim interakcijama. Često nismo ni svjesni važnosti i kompleksnosti dodira i smatramo da su druga osjetila, posebice vid i sluh, mnogo važnija. Iako vizualne informacije dominiraju ukupnim brojem informacija od osjetilnog sustava, količina podataka koje primamo kroz kožu (*Tablica 1.1*) naglašava i važnost dodira u percipiranju svijeta oko nas. Slijepe ili gluhe osobe mogu samostalno funkcionirati u zajednici u kojoj žive, dok ljudi s rijetkim stanjem koje rezultira gubitkom sposobnosti doživljavanja osjeta dodira često trpe stalne modrice, opekline i slomljene kosti u nedostatku upozorenja koje pruža dodir i bol [5]. Ljudi mogu rukovati objektima koristeći se isključivo osjetilom dodira. Bez dodira interakcija s okolinom postaje mnogo kompleksnija. Bez povratne informacije o sili s kojom djelujemo ne samo da bismo se mogli ozlijediti, već neke zadatke ne bismo mogli niti izvršiti.

Tablica 1.1. *Protok informacija osjetilnog sustava [6].*

Osjetilo	Propusnost (Bitova/sekundi)
Oči	10 000 000
Uši	100 000
Koža	1 000 000
Njuh	100 000
Okus	1 000

Druga vrsta koja će se upotrijebiti su kinestetička osjetila. Kinestetička osjetila utječu na naše fizičke vještine kao što su koordinacija, preciznost, snaga i brzina. Jedno od kinestetičkih osjetila je propriocepcija. Propriocepcija je sposobnost svjesnog ili nesvjesnog prepoznavanja položaja tijela u prostoru. Propriocepcija štiti zglobove od prekomjernih i nepravilnih pokreta koji dovode do nastanka povrede [7]. Vrlo je važna za rad s robotima. Senzorima za propriocepciju opremljena je većina robota u vidu davatelja položaja. Položaj u prostoru računa se preko stanja zglobova pomoću kinematskih matrica transformacije. Znači da je važna za snalaženje u prostoru ne samo robota, nego i ljudi.

1.2. Taktilna interakcija

Ljudska komunikacija je u biti proces razmjene informacija preko dogovorenog sistema znakova od pošiljatelja prema drugoj osobi tj. primatelju. Cilj je izazvati namijenjenu reakciju, bilo da je to prihvaćanje informacije ili promjena u ponašanju druge osobe. Da bi komunikacija bila uspješna, primatelj mora adekvatno protumačiti značenje prenesene informacije [8]. Osnovni komunikacijski alat ljudske komunikacije je jezik – komunikacijski sustav sastavljen od znakova i pravila koji se upotrebljava za međusobnu komunikaciju i razmjenu značenja. Ljudska komunikacija dijeli se na verbalnu komunikaciju, koja se ostvaruje govorom i pismom, te neverbalnu komunikaciju. Neverbalnu komunikaciju čini zbir znakova čije značenje često ovisi o kontekstu. Jedna od vrsta neverbalne komunikacije je dodir, kojim se bavi ovaj rad. Što se tiče sociološkog pogleda na interakciju dodirom, ona je opravdana zbog važnosti dodira u svakodnevnim socijalnim interakcijama od rođenja kroz odrastanje pa sve do kraja života [9]. Dodir se smatra jednim od najrazvijenijih osjetila novorođenčeta. Dodir je vrlo moćno osjetilo. Ljudi očito reagiraju na dodir, i fizički i emocionalno. Samo iskustvo dodira pokazalo se na temelju intelektualnog i emocionalnog, ali i tjelesnog razvoja [10].

Znakovni jezik sustav je vizualnih znakova koji, uz pomoć posebnog položaja (oblika šake), orijentacije, položaja i smjera pokreta ruke, tvore koncept odnosno smisao riječi. Taktilni znakovni jezik (*Slika 1.5*) sustav je taktilnih znakova pomoću kojih gluhoslijepe osobe mogu dodirom i/ili opipom primati sve informacije iz okoline. To se izvodi tako da gluhoslijepa osoba koja „sluša/gleda” (prima informaciju) stavi svoje ruke na ruke sugovornika koji joj na znakovnom jeziku „govori” (daje informaciju). Isto tako gluhoslijepa osoba koja „govori” može staviti svoje ruke na ruke sugovornika koji „sluša” (obično isto gluhoslijepa osoba). Na taj način gluhoslijepe osobe mogu svojim osjetom „vidjeti/slušati”, odnosno dodirom osjećati pokrete ruku i oblike znakova koji im daju smisao [11]. Rani taktilni jezici razvijeni su komunikaciju među ljudima, osobito kako bi se omogućilo gluhim i gluhoslijepim osobama da se sporazumijevaju.

Uza znakovni jezik određene taktilne geste mogu pospješiti komunikaciju. Sustavom dogovorenih jednostavnih znakova moguće je prenijeti učestale i važne poruke. Primjerice kratkim brzim tapkanjem različitim brojem prstiju ili nekim drugim pokretom moguće je izraziti poruku: „da”, „ne”, itd.

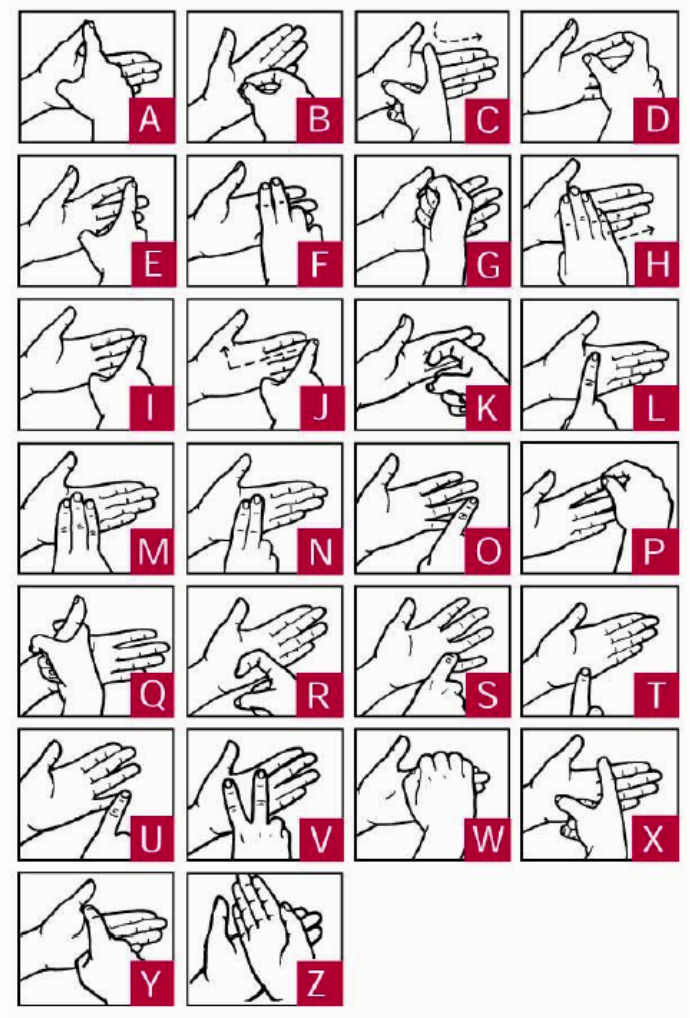

Slika 1.5. *Taktilna znakovna abeceda [12].*

Uz razvoj tehnologije, taktilni jezik i taktilna interakcija svoju primjenu nalaze i u sučeljima s tehnologijom. Komunikacijski sustav mijenja se kako sve više vodimo svakodnevnu interakciju s tehnologijom. Odsutnost osjeta dodira zahtijeva oslanjanje isključivo na vizualne informacije, no izgubljene su dodatne opipne informacije koje bismo mogli steći dodirom. Razvoj programibilnih sučelja s taktilnim mogućnostima te uređaja s haptičkim povratom sile usmjeren je na to da se nadomjesti upravo ta komponenta. Razvoj uređaja s haptičkim povratom posebice je prisutan u domeni simuliranja virtualne realnosti [13]. Upotrebom različitih vrsta uređaja moguće je prenijeti silu korisniku u skladu s očekivanim podražajem iz virtualne stvarnosti. Takav način interakcije nalazi najjednostavniji, ali i najrašireniji oblik primjene u računalnim igricama u vidu prenošenja vibracija korisniku u skladu s njegovim akcijama u igri. Nešto kompleksniji modeli simuliranja virtualne realnosti nalaze svoju primjenu u razvoju proizvoda te pružaju mogućnosti taktilne interakcije s još nepostojećim

proizvodom. Kako bi ove tehnologije bile korisne, ljudi će morati biti u mogućnosti ispravno ih upotrebljavati, prihvatiti i usvojiti.

1.3. Struktura rada

Prvo, uvodno poglavlje daje prikaz prednosti i ograničenja robotskih tehnologija. Nadalje, dan je opis osjetila, na kojima se temelji percepcija, zatim opis znakovnog jezika i taktilne interakcije. Razvoj robotske tehnologije naglašava važnost fizičke interakcije i taktilnog jezika u sučelju s tehnikom. S obzirom da je rad usmjeren istraživanju fizičke interakcije, naglašene su važnost i prednosti dodira u izravnoj komunikaciji.

U drugom poglavlju je nakon uvodnih razmatranja ukratko izložen pregled interakcijskih principa čovjeka i robota. Opisana su osnovna korisnička sučelja i dan je pregled dosadašnjih istraživanja. Predložen je model interakcije koji će omogućiti robotu prepoznavanje namjera i poruka čovjeka i u skladu s njima oblikovati svoje ponašanje. Model je razložen na reaktivno i kognitivno djelovanje.

Treće poglavlje bavi se tumačenjem fizičke interakcije čovjeka i robota. Opisane su komponente sustava. Postavlja se model klasifikacije taktilnog podražaja koji se dijeli u više opisanih kategorija. Prikazuje se višekriterijska interpretacija prostora, s različitim slojevima i vremenskim komponentama, na temelju koje se planira kretanje u konfiguracijskom prostoru. Provedeno je nekoliko eksperimenata kojima se definiraju parametri klasifikacije brzine, klasifikacije pomaka i sila.

U četvrtom poglavlju predstavlja se vjerojatnosni model. Uvode se i definiraju pojmovi potrebni za opis modela te teorijska osnova vjerojatnosti i Markovljevih procesa, koji tvore osnovu modela. Postavlja se vjerojatnosni model robotskog djelovanja koji se zasniva na višekriterijskoj definiciji radnog prostora, stohastičkom lancu stanja i pamćenju iskustvenog znanja s vremenskim razlikovanjem događaja. Eksperimentom se obrađuje problem složenosti i veličina prijelaznih matrica.

Peto poglavlje bavi se validacijom i verifikacijom predložene metodologije. Simulacijama i eksperimentima ispituje se ispravnost i učinkovitost razvijenih algoritama i klasifikacija. Eksperimenti su provedeni u laboratorijskim uvjetima upotrebom lagane robotske ruke i kapacitivnog senzora („umjetne kože”). Eksperimentalnom validacijom potvrđeno je da predloženi modeli ispunjavaju postavljene ciljeve.

Na temelju svih ostvarenih rezultata i zapažanja u posljednjem su poglavlju sažeti zaključci rada. Uz kritički osvrt na rezultate predlažu se smjerovi budućeg istraživanja koje bi se temeljilo na spoznajama proizašlim iz provedenog istraživanja.

2. Interakcija čovjeka i robota

Interakcija [14]

1. Međusobni utjecaj dvaju ili više djelovanja ili akcija; međudjelovanje.

2. Psihološki odnos između dviju ili više osoba koji dovodi do međuovisnosti u njihovu ponašanju i doživljavanju.

3. Fizička situacija u kojoj ponašanje jednog sistema utječe na ponašanje drugog sistema, proces u kojem više tijela djeluju jedno na drugo, što rezultira nekim fizikalnim ili kemijskim promjenama na tim tijelima.

Nove robotske primjene nalažu suradnju robota i ljudi, bez obzira na to radi li se o industrijskoj ili uslužnoj primjeni. Zajednička radna područja omogućavaju nam lakše upravljanje robotima i suradnju na nekim zadaćama. Takva radna okolina zahtijeva promjene u načinima na koje se roboti kreću, uče i ulaze u interakciju s korisnicima. Ako želimo da roboti rade u ljudskoj okolini, interakcija, posebice intuitivna interakcija, ključ je suradnje i rada s robotima. Roboti moraju moći surađivati s ljudima, i to intuitivno, kao partneri. Napredak u robotici i autonomiji robota omogućuje stvaranje partnerstva u kojem robot djeluje kao suradnik, a ne kao alat [15]. Na taj način roboti i ljudi rade „rame uz rame". Roboti i ljudi preuzimaju zadaće koje su unutar granica njihovih mogućnosti i koje su kompetentniji izvršiti. Pravilnom raspodjelom rada može se poboljšati efikasnost djelovanja. Suradnja se može ostvariti kada oba mogu ponuditi nešto jedinstveno i kada suradnjom mogu dobiti nešto, tj. kada suradnja pogoduje objema stranama. Zadaća ljudi u takvom partnerstvu je da obavljaju zadatke koje zbog kompleksnosti samo ljudi mogu izvoditi, a roboti im asistiraju. Primjerice dodavanjem potrebnih alata u pravo vrijeme, čime pomažu pri izvođenju kompleksnih ili nelagodnih pokreta tako da ih olakšaju čovjeku, ili pravodobnim pružanjem relevantnih usluga ili informacija. Kako bi robot bio efikasan asistent, mora zaključivati o namjerama čovjeka na temelju dostupnih informacija i prethodnih iskustava ako su te informacije nepotpune, što se često događa prilikom rada s ljudima. Na temelju konteksta robot mora predvidjeti namjere i proaktivno djelovati kako bi pomogao da se te namjere ostvare.

Sučelja interakcije s robotima protežu se od elementarnih oblika u vidu uporabe tipki ili upravljačkih konzola pa sve do najkompleksnijih kognitivnih modela. Svaki se pristup interakciji u svojoj osnovi zasniva na modelima izvođenja akcije na temelju bilo koje vrste percepcije. Počevši od najjednostavnijih oblika interakcije upotrebom upravljačke konzole pa sve do vrlo složenih načina upravljanja. I tako dolazimo do suvremenih robota. Za programiranje robota moramo imati za to osposobljenu stručnu osobu. Imperativ je da razumijemo vektore i prostorne transformacije (*Slika 2.1*), poznajemo programske jezike i sve ostale alate kojima se moramo naučiti koristiti umjesto intuitivnih načina interakcije. To dovodi do toga da korisnici bez predznanja ne mogu upravljati njima, što ih udaljava od tehnologije. Postavlja se pitanje nije li bolje da robota programira osoba koja je stručna za zadaće koje će robot obavljati, i to intuitivnim metodama. Da bismo postigli intuitivnu interakciju, moramo unaprijediti korisnička sučelja. Moramo dizajnirati robote i sučelja koje ljudi mogu naučiti upotrebljavati u kratkom roku. Potrebno je pojednostavniti sučelja kako bi se poboljšala interakcija s ciljem povećanja učinkovitosti prilikom obavljanja raznih zadataka.

O vrsti i karakteristikama interakcije ovisi je li robot više ili manje prihvatljiv među ljudima. Sučelje između čovjeka i robota određuje interakcijske sposobnosti robota, odnosno koliko je robot prilagodljiv u međudjelovanju s čovjekom. Ako za interakciju čovjek treba imati veliko predzadnje o samoj interakciji, takvo je sučelje manje prihvatljivo u usporedbi s onim koje ne zahtijeva preduvjete za interakciju. Dakle, robot treba intuitivno prepoznati namjeru u interakciji čovjeka.

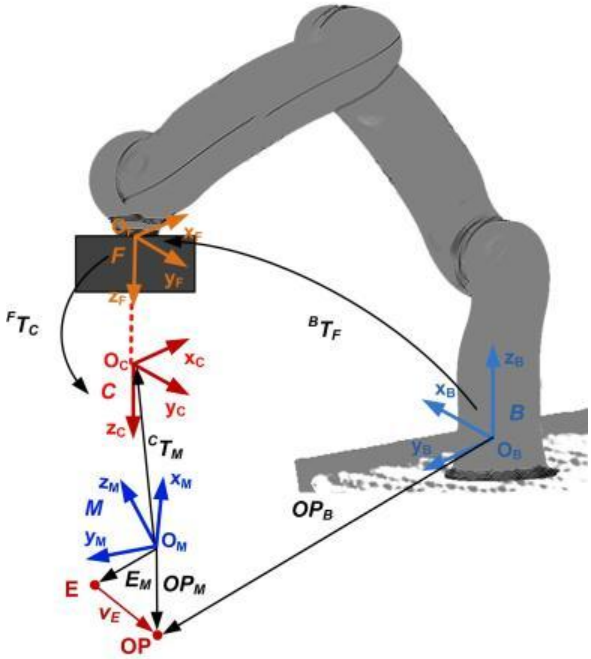

Slika 2.1. *Transformacije koordinatnih sustava robota.*

Primarni cilj istraživanja je definirati modele interakcije i načiniti robote koji su sigurni u interakciji s čovjekom. Time bi se radni prostor robota premjestio iz izoliranih prostora u kojima je pristup ljudima zabranjen u prostor gdje se radno područje čovjeka i robota preklapaju.

2.1. Korisnička sučelja – od HCI[1] do HRI[2]

Ljudi su ponekad frustrirani uređajima, što proizlazi iz sve veće složenosti sučelja. Svakodnevni život i interakcija s tehnologijom uza sve prednosti ponekad izgledaju kao borba protiv pogrešaka, zbunjenosti, frustracije, te kontinuiranog ciklusa ažuriranja i održavanja uređaja. Prilagodba oblika sučelja čovjeku (eng. *Human-centered design* – HCD) je proces

[1] HCI – *Human Computer Interaction*.
[2] HRI – *Human Robot Interaction*.

kojim se nastoji osigurati zadovoljenje potreba ljudi, te da proizvod bude razumljiv i koristan, da ostvaruje željene zadatke, a da iskustvo korištenja bude pozitivno i ugodno. Učinkovit dizajn treba zadovoljiti velik broj ograničenja i problema, uključujući oblik i formu, pouzdanost i učinkovitost, razumljivost i jednostavnost uporabe. HCD je postupak za rješavanje tih zahtjeva, ali s naglaskom na rješavanje pravog problema, i to tako da se zadovolje ljudske potrebe i mogućnosti [1].

U interakciji čovjeka i računala (eng. *human computer interaction* – HCI) poznavanje mogućnosti i ograničenja čovjeka upotrebljava se za projektiranje sustava, softvera, zadataka i alata. Svrha je općenito poboljšati produktivnost pružanjem ugodnog i zadovoljavajućeg iskustva uporabe. Interakcija čovjeka s računalom moguća je pomoću ulazno-izlaznih jedinca (*Slika 2.2*).

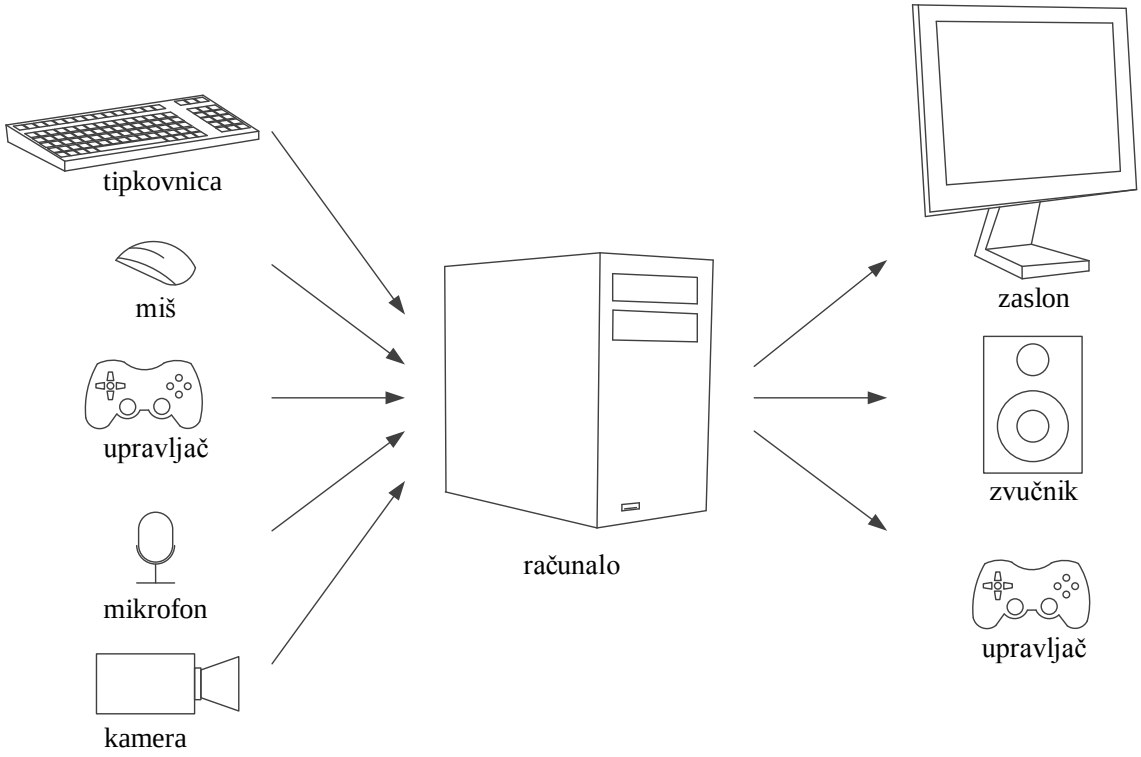

Slika 2.2. *Ulazno-izlazne jedinice.*

U oblikovanju interakcijskih sučelja s robotima kao uzor se uzima HCI domena, koja se razvija već godinama jer su ljudi mnogo više u interakciji s računalima nego s robotima. Iskustva iz oblikovanja interaktivnih sučelja čovjeka i računala prenose na se na interakciju s robotima.

Standardnom upravljanju robotima pristupa se uz pomoć tipki upravljačke konzole (*Slika 2.3*) odabirom naredbi iz raznih izbornika. Uz pomoć tipki i izbornika definiraju se točke u

prostoru u kojima robot obavlja određene radnje te točke kroz koje robot prolazi, čime se oblikuju trajektorije. Dodatno se unose i potrebni parametri brzine, akceleracije i ostale komponente potrebne za izvođenje robotskog programa. Unošenje koordinata numerički zahtijeva vrlo precizne mjere. Zbog toga upravljačke konzole omogućavaju korisniku da se približi robotu i ručnim pokretanjem robota obavi registraciju i podešavanje prostornih koordinata točaka.

Slika 2.3. *Upravljačka konzola.*

Iako je uz pomoć upravljačke konzole moguće programiranje robota, ono nije intuitivno. Često se pri radu upotrijebi pogrešna tipka ili se odabere pogrešan koordinatni sustav, što rezultira neželjenom kretnjom. Razvoj i komercijalizacija „popustljivih" robotskih ruku, primjerice Kuka LWR4+ (*Slika 2.4*), otvara nove mogućnosti u interakciji čovjeka i robota. Primjenom vanjske sile, odnosno korisnika, moguće je jednostavno prostorno vođenje robota. Time je omogućen jednostavan i intuitivan način interakcije čovjeka i robota te prijenos informacija izravno kroz kontakt s robotom. To je ujedno i najizravniji način prijenosa informacija, sličan interakciji dviju osoba, što u nekim slučajevima može pružiti bržu, sigurniju i više intuitivnu komunikaciju nego druge vrste interakcije. Interakcijskim modelima otvara se mogućnost odabira željenog zadatka jednostavnim usmjeravanjem prema određenom cilju.

Slika 2.4. *Kuka robotska ruka – LWR4+ (*lightweight robot*).*

Prilikom suradnje s ljudima roboti novih generacija certificirani za rad u ljudskoj okolini djeluju s ograničenjima maksimalne dinamičke snage (80 W) ili maksimalne statičke sile (150 N), kao i s ograničenjem maksimalne brzine (250 mm/s) [16]. Popustljivost i ograničenja sile omogućavaju korisniku da jednostavno zaustavi robota u slučaju nužde, bez potrebe za odvojenim sučeljem za zaustavljanje ili tipkom hitnog zaustavljanja (eng. *emergency stop button*).

2.2. Pregled dosadašnjih istraživanja

Brojna istraživanja bave se primjenom industrijskih robota kao suradnika prilikom izvođenja operacija sklapanja [17 – 21]. Tome pridonose brze promjene na globalnom tržištu. Ubrzane promjene tržišnih trendova i želja kupaca odražavaju se na skraćivanje proizvodnih ciklusa, pri čemu tradicionalna montaža ne može odgovoriti na zahtjeve učinkovitosti. Uporaba robota kao suradnika naglašava sve prednosti ljudske prilagodljivosti i inteligencije, istodobno iskorištavajući djelovanje robota u postupcima gdje se pojavljuju zamorni, ponavljajući ili pak za čovjeka zahtjevni elementi rada. Robotski asistenti neovisno o primjeni sudjeluju u dodavanju potrebnih alata ili čak u izvođenju određenih radnji koje mogu obaviti bolje od čovjeka. U takvim primjenama istraživanja se uvelike oslanjaju na pasivnu interpretaciju radne okoline primjenom vizijskih sustava, lasera, senzora zvuka itd. [18 – 20]. Interakcija s robotom uglavnom se svodi na analizu naredbi zadanih glasom, interpretaciju gesti ili pogleda.

Posebno važan smjer u domeni istraživanja interakcije čovjeka i robota je istraživanje fizičke interakcije [21 – 27]. Važnost proizlazi iz značaja koji dodir ima za čovjeka u svakodnevnim

socijalnim interakcijama [9]. Koristimo se dodirom neizostavno u svakodnevnom životu, a navikli smo na jednostavnu manipulaciju objekata u tri dimenzije [28]. Istraživanja objavljena u [29, 30] ističu prednosti taktilne percepcije, posebice u situacijama kada su drugi oblici percepcije ograničeno primjenjivi, osobito kada nije moguće izbjeći kontakt s objektima ili čovjekom.

U istraživanjima taktilne percepcije upotrebljavaju se razne tehnologije i pristupi, od elementarne binarne detekcije kontakta pa sve do složenijih parametarskih modela s mjestom kontakta, veličinom dodirne plohe i sila prilikom dodira. Mjerni uređaji protežu se od senzora sile s malim mjernim područjem pa sve do senzora dodira koji prekrivaju cijelu robotsku strukturu [18]. Mjerno područje, razlučivost i pokrivenost robotske ruke senzorima ima važnu ulogu u tome koje je vrste ljudskog kontakta moguće detektirati i u kojim vrstama situacija. Moguća je uporaba senzora sile i momenata na prirubnici robotske ruke, no takav je pristup ograničen mjerenjima vanjskih sila koje sa javljaju samo nakon prirubnice [31]. Nove tehnologije [32, 33] omogućavaju mjerenje momenta u svim zglobovima robotske ruke i komunikaciju visoke frekvencije [34], zbog čega je moguće ostvariti odgovarajuće usklađene odzive sustava. Još jedan vid je uporaba niza taktilnih senzora kao neki vid „kože" robota. Takvim senzorima moguće je razaznati ljudski dodir s robotom, kao i neposrednu blizinu čovjeka robotu [35 – 39]. Složeniji oblici sastoje se od velikog broja senzora kojima je moguće vrlo fino detektirati i lokalizirati dodirno mjesto [40, 41].

Također, kako navode autori jedne studije [42] na području taktilne interakcije, u usporedbi s ostalim vrstama, provedeno je malo istraživanja uslijed tehnološke i sociološke složenosti. Autori se u tom radu bave načinom na koji ljudi prenose svoja emocionalna stanja putem dodira na robotskog ljubimca te koje su njihove očekivane reakcije od strane ljubimca. Rezultat navedenog istraživanja je stvaranje baze gesti koje ljudi često upotrebljavaju te koje emocije su vezane za opisane geste. Tim radom je demonstrirana mogućnost uporabe dodira kao sredstva prenošenja emocija, a samim time indirektno i mogućnost upravljanja.

Dodir se tako u raznim istraživanjima upotrebljava za interpretaciju interakcije. S obzirom na pristup, interakcija dodirom dijeli se na dvije kategorije. U prvoj kategoriji izdvojit će se pristupi koji odgovaraju neočekivanom kontaktu između čovjeka i robota. Takvi događaji odgovaraju nenamjernim sudarima čovjeka i robota tijekom djelovanja robota. Za ostvarivanje sigurnosti prilikom zajedničkog rada, sprečavanje sudara u blizini čovjeka i zaustavljanje prilikom samog sudara, istraživanja se u pravilu oslanjaju na senzore koji prekrivaju velik dio površine robotske ruke [43 – 45]. Nedostatak takvog pristupa proizlazi iz

činjenice da nedostaje mogućnost prilagodbe rada sustava nakon kolizije kako bi se ona izbjegla u budućim radnjama.

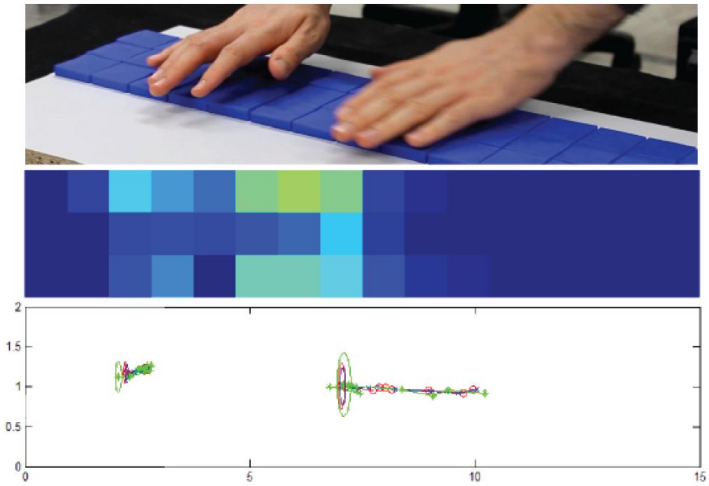

Slika 2.5. *Taktilni senzor [45].*

Druga kategorija je namjerni dodir. Djelovanje robota ovisi o taktilnom kontaktu s ljudima. Robot očekuje ljudski dodir i njime se oblikuje ili obavlja prilagodbu ponašanja. Dodir se upotrebljava kao sredstvo komunikacije i prenošenja namjera. Na temelju dodira mogući su razni modeli primjene. Čovjek može voditi robota po prostoru [32] i oblikovati kretnje koje će se kasnije replicirati [46]. Uz vođenje robota po prostoru, istraživanja se bave i problemom zajedničkog prenošenja predmeta rada, gdje se sudionici moraju prilagoditi jedan drugom [47, 48]. U daljnjim se istraživanjima uz pomoć taktilnih uređaja na temelju unosa određenih obrazaca uz pomoć više prstiju [49] ili čak različitih orijentacija ljudske ruke [50] donosi zaključak o željenom ponašanju robota. Nekoliko radova [31, 51, 52] predstavlja primjenu percepcije za zaključivanje o korisnikovim namjerama promatranjem taktilnih gesta. Geste se sastoje od povremenih, netočnih guranja robota s ciljem izmjene putanja u prostoru. U [51] je provedena korisnička studija s ciljem usporedbe dvaju tipova korisničkog sučelja – upotrebom gesti i upotrebom izbornika. Oblikovane su intuitivne geste, povezane s asistencijom u kirurškim aplikacijama. Rezultati studije pokazali su kako korisnici radije upotrebljavaju naredbe gestama te kako je to brži način upravljanja iako je veća mogućnost davanja pogrešne naredbe.

Jedan od primjera gdje fizička interakcija može doći do izražaja je primjena robota u medicini, ponajviše u kirurškoj primjeni. Danas se u kirurškim primjenama većinom upotrebljavaju daljinski navođeni roboti, no primjenjuju se i autonomni roboti, opremljeni

odgovarajućom senzorikom koja omogućava samostalan rad robota, ali i interakciju s kirurgom [53 – 55].

S obzirom na to da su ljudski postupci i stanja okoline često nepredvidivi, dio istraživanja u domeni interakcije čovjeka i robota oslanja se na vjerojatnosne metode za oblikovanje robotskog djelovanja [56 – 59]. U navedenim istraživanjima prevladava primjena Bayesovih mreža [58, 59]. Bayesove mreže su matematički model za donošenje odluka koje ovise o neizvjesnim i uzročno povezanim događajima i stanjima. Za oblikovanje robotskog djelovanja, uz Bayesove mreže upotrebljava se i Markovljev proces, odnosno Markovljev lanac [60]. Markovljevi procesi nalaze široku primjenu u raznim područjima prepoznavanja obrazaca, primjerice u biologiji, strojnom učenju, prepoznavanju govora, računalnom prijevodu, itd. [61, 62]. U radu [60] je predstavljen algoritam za prepoznavanje namjera koji upotrebljava vjerojatnosti stanja sustava. Ulaz podataka za algoritam odvija se vizijskom obradom radnog prostora koji uključuju poznate predmete i ljudske akcije te listu mogućih ljudskih namjera. Izlaz algoritma je prepoznata ljudska namjera.

Kako bi bilo koji model temeljen na teoriji vjerojatnosti mogao naći svoju primjenu, potrebno je odrediti odnose varijabli u modelu. Postoji nekoliko načina kako dolazimo do informacija o odnosima. Prvi način je da stručnjaci koji definiraju odnose među varijablama ekspertno definiraju problem prepoznavanjem prethodnih i uvjetnih vjerojatnosti. Drugi način definiranja odnosa varijabli koristi se metodama strojnog učenja. Strojno učenje svodi se na optimizaciju parametara modela putem triju osnovnih pristupa: nadzirano učenje (klasifikacija i regresija), nenadzirano učenje i podržano učenje. Kod učenja podrškom (eng. *reinforcement learning*) učenje se odvija u interakciji s okolišem. Zadatak robota je naučiti upravljačku strategiju putem procesa pokušaja i pogrešaka. Algoritmi podržanog učenja razvijeni u [63, 64] omogućavaju suradnju čovjeka i robota unutar procesa učenja koji se koristi prednostima ljudske inteligencije i znanja. Učenje podrškom upotrebljava se i za oblikovanje trajektorija i optimizaciju parametara putanje i kretanja [65].

Opisane metode određuju djelovanje robota na temelju zahtjeva čovjeka, vjerojatnosti i trenutnog stanja robota, no imaju i svojevrsna ograničenja. Modeli koji se temelje na stacionarnom odnosu varijabli vjerojatnosti nisu primjenjivi u procesima koji se mijenjaju s vremenom. Ekspertnim definiranjem odnosa varijabli potrebno je unaprijed odrediti odnose među varijablama te prilikom svake izmjene procesa odrediti nove vrijednosti. Pri učenju podrškom nije potrebno unaprijed definirati odnose, ali potrebne su pozitivne/negativne nagrade kojima se oblikuju vrijednosti varijabli. Glavni nedostatak učenja podrškom je spora konvergencija prema zadovoljavajućem rješenju te je potreban velik broj podataka kako bi se

odredile odgovarajuće vrijednosti varijabli. Iz navedenih razloga u radu će se vjerojatnosti oblikovati dinamički te će se razmotriti mogućnost unapređenja postojećih metoda.

Nadalje, istraživanja se bave metodama „programiranja pokazivanjem" (eng. *programming by demonstration*), koje se temelje na učenju vještina prezentacijom postupka, umjesto implicitnog programiranja u odgovarajućem programskom jeziku [32, 66]. Programiranje demonstriranjem nudi interaktivna sredstva za podučavanje, omogućavajući programiranje stručnjacima iz područja primjene koji mogu biti needucirani u području robotike. Kako se roboti upotrebljavaju u sve većem broju aplikacija, mogućnost da ih se nauči sigurno i precizno obavljati poslove postaje sve nužnija. U istraživanjima [46, 67] robot uči nove putanje tako da glatko može oponašati ponašanje učitelja, uz optimizaciju parametara kretanja. Na temelju prethodnih putanja oblikuje se nova putanja kao skup točaka (*Slika 2.6*).

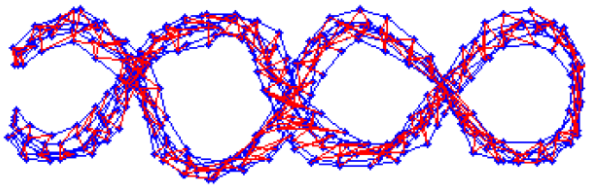

Slika 2.6. *Optimizacija putanje kretanja [67]*.

U istraživanjima se obavlja oblikovanje i unapređivanje putanja kroz taktilnu interakciju s korisnikom. Potom se naučene putanje upotrebljavaju za izvršavanje zadataka, no ograničenje modela predstavljaju promjene radne okoline uslijed kojih je potrebna intervencija korisnika.

U navedenim istraživanjima dodir se upotrebljava za interpretaciju interakcije. Bilo da se model temelji na teoriji vjerojatnosti ili nekoj drugoj metodi, robot djeluje na temelju izričite naredbe čovjeka. S obzirom na promjenjivost prostora, posebice prilikom prisutnosti čovjeka u radnom prostoru, takvi modeli nisu u potpunosti primjenjivi. Ograničenje je nedostatak autonomnog planiranja. Modeli ne sadrže komponentu prostornog planiranja uslijed promjena u radnom prostoru, već se prilagodba u potpunosti prepušta čovjeku. Prilikom autonomnog djelovanja u promjenjivim okolinama potrebno je nadograditi modele prostornim planiranjem. Planiranje putanje u radnom prostoru robota jedna je od važnih komponenata sustava upravljanja robotom. Kako bi se robot mogao samostalno kretati kroz prostor, potrebno je implementirati prostorno planiranje. Djelovanje u realnom vremenu nužno je u radnim uvjetima u kojima prepreke kretanju robota nisu unaprijed poznate, kao prilikom rada s ljudima [68]. Postoji nekoliko pristupa planiranju, od kojih se izdvaja planiranje u konfiguracijskom prostoru gdje je robot predstavljen kao točka. Planiranje u

konfiguracijskom prostoru se pomoću algoritama za planiranje kretanja svodi na problem pronalaženja najkraćeg puta u grafu [69, 70]. Kod navedenih pristupa planiranju segmenti prostora se klasificiraju kao zauzeti ili slobodni. U navedenim radovima ne postoji distinkcija između objekata u okolini i čovjeka, već se istovjetno svrstavaju u prepreke koje je potrebno izbjeći. Zbog toga su ograničeno primjenjivi u prostorima u kojima djeluju ljudi. Predloženom višekriterijskom interpretacijom radnog prostora s distinkcijom između objekata u okolini i čovjeka pokušat će se predstaviti različite vremenske domene kretanja ljudi i promjene položaja objekata.

U istraživanjima [71, 72] robot i čovjek simultano obavljaju zadatke manipulacije u neposrednoj blizini. Uz pomoć vizijskog sustava, s određenom vjerojatnosti, definira se položaj čovjeka u radnom prostoru robota.

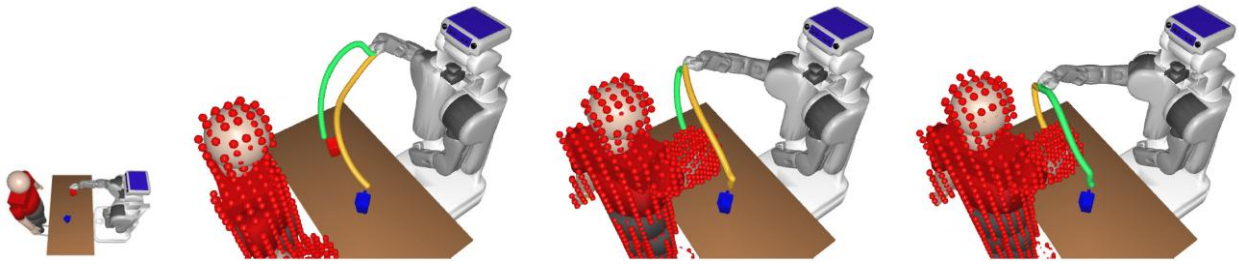

Slika 2.7. *Putanja u prisutnosti čovjeka [71].*

Čovjek je predstavljen kao dinamička prepreka u modelu. Na temelju položaja čovjeka oblikuje se kretanje u konfiguracijskom prostoru robota. Ograničenje ovih istraživanja je nedostatak interakcije u vidu čovjekova davanja naredbe robotu, tj. što isključivo obrađuju problem planiranja kretanja za određeni zadatak.

Istraživanja u domeni interakcije čovjeka i robota relativno su novo područje te, posebice na području taktilne interakcije, u usporedbi s ostalim vrstama, nema mnogo objavljenih istraživanja. U navedenim istraživanjima opisane metode ne rješavaju probleme interakcije čovjeka i robota tako da integriraju taktilnu interakciju i mogućnost izričite naredbe čovjeka s planiranjem kretanja u radnom prostoru. Zbog toga se u radu predlaže model interakcije kojim će se objediniti obje domene. Takav model interakcije omogućava da se robot ponaša autonomno u smislu da ne djeluje samo na temelju izričite naredbe čovjeka, već i na temelju prethodnih iskustava, stanja okoliša i samog robota.

2.3. Predloženi model interakcije

Russell i Norvig [73] dijele grupe entiteta (sustava, agenata[3], itd.) u pet klasa na temelju stupnja njihove prividne inteligencije i sposobnosti. Najniži stupanj je jednostavni refleksni entitet koji djeluje samo na temelju trenutnog stanja, zanemarujući ostatak događaja u prošlosti. Model entiteta temelji se na pravilu uvjet – akcija: ako je uvjet, onda akcija (*if – then*). Takav je pristup posebice prigodan za uređene okoline u kojima je set mogućih događaja unaprijed poznat. Tada je moguće uvjetovanjem oblikovati cjelokupno djelovanje robota. No u kompleksnim okolinama koje nisu potpuno uređene takav model nije moguće samostalno primijeniti. U slučaju događaja koji nije definiran uvjetom takav model prestaje funkcionirati. No jednostavno uvjetovanje donosi i određene prednosti, od kojih je glavna računska jednostavnost koja rezultira brzom obradom podataka. Zbog toga se reaktivno djelovanje odvija kada nema dovoljno vremena za složenu obradu podataka i razmatranje svih potencijalnih posljedica takvog djelovanja. Zato je prigodno upotrijebiti ga kako bi se zaštitilo korisnika od ozljede u slučaju dodira ili kolizije robota i čovjeka. Predstavlja „refleks" sustava uzrokovan podražajem koji je, zbog sigurnosti, asocijativno vezan za zaustavljanje kretanja.

Obilježja reaktivnog djelovanja:

- temelji se na pravilima uvjet – akcija (*if – then*)
- odabire akciju na temelju trenutnog stanja
- ne vodi računa o posljedicama svog djelovanja.

Algoritam 2.1. *Reaktivno djelovanje – uvjetovanje.*

Parametri:

$X=\{X_1, X_2\}$ – moguća stanja sustava

A, B – moguća djelovanja robota

Algoritam:

```
početak
     ulaz (stanje);
ako je stanje=X1tada
          izlaz (A);
inače
          izlaz (B);
kraj
```

[3] U području umjetne inteligencije agent je samostalni entitet koji promatra kroz senzore i djeluje na okolinu pomoću aktuatora i usmjerava svoju aktivnost prema ostvarivanju ciljeva.

Cilj istraživanja je razvoj modela pomoću kojeg će robot donositi odluke o svojem djelovanju putem fizičke interakcije s čovjekom. Zahtjevi koji se pri tome postavljaju za model interakcije su sljedeći:

- klasifikacija fizičke interakcije s ciljem tumačenja značenja interakcije
- procjena i odabir najizglednijeg djelovanja uslijed nesigurnosti svojstvenih nepredvidivosti ljudskog ponašanja
- planiranje ponašanja u skladu s okolinom i fizičkom interakcijom
- sigurnost čovjeka prilikom djelovanja robota u zajedničkom radnom prostoru.

Model interakcije je proširenje osnovne činjenice da se svaka akcija zasniva na percepciji. Time interakcija počinje od percepcije. Osnova percepcije je organizacija i interpretacija podataka iz osjetila. Kod robota osjetila predstavlja sofisticirana senzorska oprema. Senzorske podatke treba klasificirati. Klasifikacija je identificiranje kojoj kategoriji taktilna senzacija pripada. Da bi se zadani problem interpretacije podataka riješio, klasifikacija se provodi na temelju ulaznih parametara položaja $T(x, y, z, \psi, \theta, \phi)$, sile $F(F_x, F_y, F_z, M_x, M_y, M_z)$ i kapacitivnog senzora ($K_0, K_1,..., K_{12}$) (*Slika 2.8*), koji se ostvaruju prilikom fizičke interakcije. Znanja koja sadrže značenja stanja senzora pomažu u tumačenju primljenih podražaja. Ta su znanja pohranjena u modelu u obliku taktilnog jezika i pripadajućih klasifikacijskih parametara. Uslijed raznovrsnosti i složenosti fizičke interakcije, potrebno je raščlaniti interakciju na sastavne elemente te odrediti utjecajne parametre. Prepoznavanjem čovjekovih namjera robot može surađivati s ljudima, pa prepoznavanje ima ključnu ulogu u intuitivnoj suradnji čovjeka i robota.

Kako je ljudsko ponašanje nepredvidivo [74], zahtjevno je oblikovati model koji može predvidjeti sljedeću radnju čovjeka i položaj ljudskog tijela ili dijela ljudskog tijela prilikom obavljanja zadatka. Zbog toga se model temelji na vjerojatnosti. Točna i pouzdana procjena potrebna je za siguran i pouzdan rad robota u ljudskim sredinama gdje je visoka nesigurnost zbog svojstvene nepredvidivosti. Model se oblikuje kao slijed radnji koje robot izvršava, što u konačnici rezultira robotskim djelovanjem. Potrebno je raščlaniti djelovanje na pojedine elemente djelovanja koji tvore stohastički lanac kroz skup stanja. Vjerojatnosti $P(X_n = s_n | X_{n-1} = s_{n-1}, X_{n-2} = s_{n-2}, X_{n-3} = s_{n-3})$ u stohastičkom lancu moraju se dinamički mijenjati s obzirom na utjecaj fizičke interakcije. U modelu će se posebna pozornost posvetiti definiranju varijabli vjerojatnosti stohastičkih procesa koje proizlaze iz interakcije s čovjekom. U tom pogledu vjerojatnost za prelazak u naredno stanje oblikuje se ovisno o prethodnim sljedovima elemenata djelovanja, tj. iskustvenim znanjima ($P_{t-1}\times\lambda^0 + P_{t-2}\times\lambda^1 + \ldots + P_{t-m}\times\lambda^m$).

Kako bi robot imao određenu autonomiju i mogućnost kretanja kroz prostor, potrebno je implementirati mogućnost prostornog planiranja. Problem prostornog planiranja vezan je za prostornu mapu i putanje u prostoru. U sklopu modela definira se višekriterijska interpretacija radnog prostora u kojoj postoji distinkcija između objekata u okolini, čovjeka, samog robota te putanja robota.

Prostorni utjecaj $D = (d_{ij})$ i utjecaj slijeda događaja oblikuje kognitivno djelovanje u koje su ugrađeni spoznajni modeli razaznavanja i predviđanja obrazaca ponašanja uzimajući u obzir prethodno iskustvo i stanje okoline $M = (p_{ij} \times d_{ij})$.

Prilikom interakcije nužno je osigurati sigurnost čovjeka. Umjesto distanciranja robota od čovjeka i odvajanja u zaštitne kaveze, upotrebljavaju se nove generacije robota ograničene brzine i sile izvođenja operacija. Sigurnost se ostvaruje na dva načina – aktivna sigurnost i planirana sigurnost. Aktivna sigurnost prilikom djelovanja robota ostvaruje se reaktivnim djelovanjem. Planirana sigurnost temelji se na „kognitivnom" djelovanju na temelju prethodnih iskustva. Planiranjem kretanja pokušava se ostvariti kretnje koje ne rezultiraju kolizijom s korisnikom.

Na temelju iznesenoga može se postaviti sljedeća hipoteza:

Intuitivno ponašanje robota u ljudskoj okolini moguće je postići interpretacijom fizičke interakcije pomoću vjerojatnosnog modela koji se zasniva na višekriterijskoj definiciji radnog prostora, stohastičkom lancu stanja i pamćenju iskustvenog znanja s vremenskim razlikovanjem događaja. Predloženim modelom moguće je oblikovati funkciju robotskog djelovanja u interakciji s čovjekom.

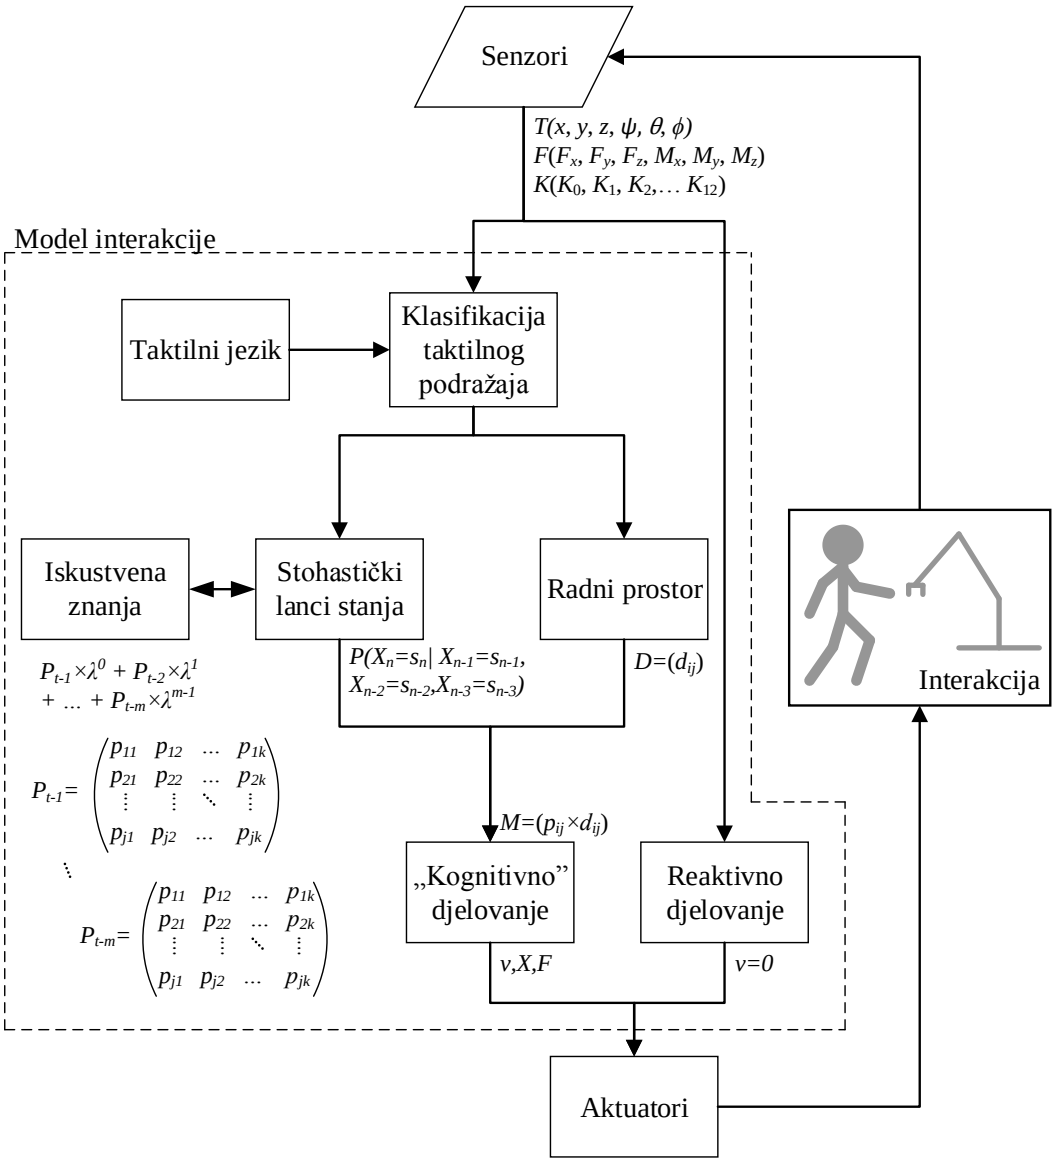

Slika 2.8. *Predloženi model interakcije.*

3. Tumačenje fizičke interakcije

It is strange that the tactile sense, which is so infinitely less precious to men than sight, becomes at critical moments our main, if not only, handle to reality.

Vladimir Nabokov

Taktilnom interakcijom olakšava se komunikacija između čovjeka i robota. Komunikacija je ključna za interakciju te zbog toga za korisnika mora biti zadovoljavajuća i smislena. Mora biti jasna, sažeta i pristupačna. Interakcijom je moguće ostvariti sigurnost prilikom autonomnog djelovanja u zajedničkom radnom prostoru i zadati robotu naredbe. Naredbe robotu primjenjuju se prilikom programiranja robota demonstriranjem, ali i zahtjevima usluga ili djelovanja prilikom autonomnog rada robota. Važne stavke prilikom oblikovanja taktilne interakcije su intuitivno korištenje, svestranost, mogućnost jednostavnog proširivanja seta naredbi i računska jednostavnost za obradu u realnom vremenu.

3.1. Hardver i softver

Budući da se ovo istraživanje zasniva na primjeni dodira kao sredstva interakcije, upotrebljavaju se senzori i robot koji mogu reagirati na podražaj dodirom. U ovom se radu tumačenje taktilne interakcije obavlja upotrebom lagane robotske ruke i kapacitivnog senzora („umjetne kože") s ciljem upravljanja.

Komponente sustava su robot (upravljačka jedinica robota i robotska ruka), računalo i kapacitivni senzor. *Slika 3.1* prikazuje osnovne komunikacije komponenata potrebnih za rad sustava. Središnji dio sustava je računalo. Na njemu su pohranjeni svi podaci i upravljački procesi potrebni za rad robotske ruke. Upravljačka jedinica robota je prilikom rada sustava u stalnoj komunikaciji s računalom. Čitavo vrijeme se u oba smjera izmjenjuju podaci između njih, i to velikom brzinom. Dalje, za rad sustava potreban je kapacitivni senzor. Elektrode kapacitivnog senzora pričvršćene su na robotsku ruku i senzor utječe na gibanje robotske ruke preko upravljačke jedinice na način koji je prethodno definirao korisnik.

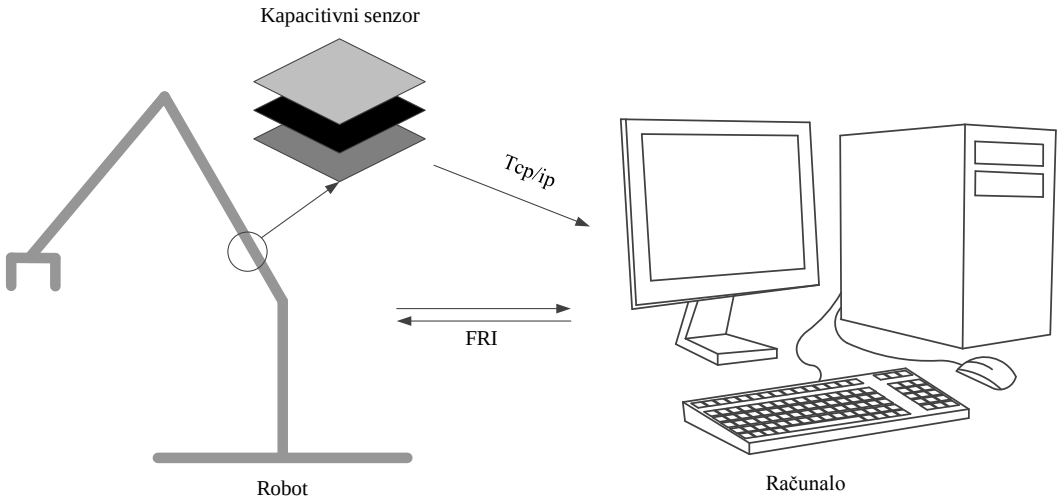

Slika 3.1. *Prikaz sustava.*

3.1.1. Kapacitivni senzor

Kapacitivni senzori elektronički mjere kapacitet između dvaju ili više vodiča u dielektričnom okruženju, obično u zraku ili tekućini [75]. Na temelju dielektričnosti praznog prostora ε_r, dielektričnoj konstanti ε_0, površine S i razmaka d može se postaviti sljedeća formula za izračun kapacitivnosti C:

$$C = \frac{\varepsilon_0 \varepsilon_r S}{d}. \qquad (3.1)$$

Kapacitivnim senzorom moguće je razaznati ljudski dodir s robotom, kao i neposrednu blizinu čovjeka. Kako je ljudsko tijelo električni vodič, dodirivanjem površine senzora mijenja se elektrostatsko polje, što je mjerljivo kao promjena kapaciteta. Kapacitivni senzori upotrebljavaju se kada je potrebno detektirati čovjeka pri vrlo malim silama dodira. S adekvatnim postavkama senzor osjeća ruku ili tijelo nekoliko centimetara udaljene od senzora. Detekcija blizine je jednostavna i učinkovita primjena kapacitivnih senzora. Postoji mala promjena u kapacitetu kada se prilazi elektrodi kroz zrak. Ako su pragovi postavljeni nisko, signal se može primijetiti čak i na udaljenosti od nekoliko centimetara.

U cilju poboljšanja interakcije čovjeka i robota razvijen je jednostavan kapacitivni senzor (*Slika 3.2*). Predstavljeno rješenje koristi se fleksibilnom dvoslojnom elektrodom, kao svojevrsnom „kožom" robota, Arduino kontrolerom i MPR 121 senzorskom pločicom kako bi se omogućila interakcija. Razvijen model interakcije osigurava sigurnije djelovanje robota usporavanjem i zaustavljanjem kretanja robota kada je čovjek preblizu robotu ili u dodiru s robotom.

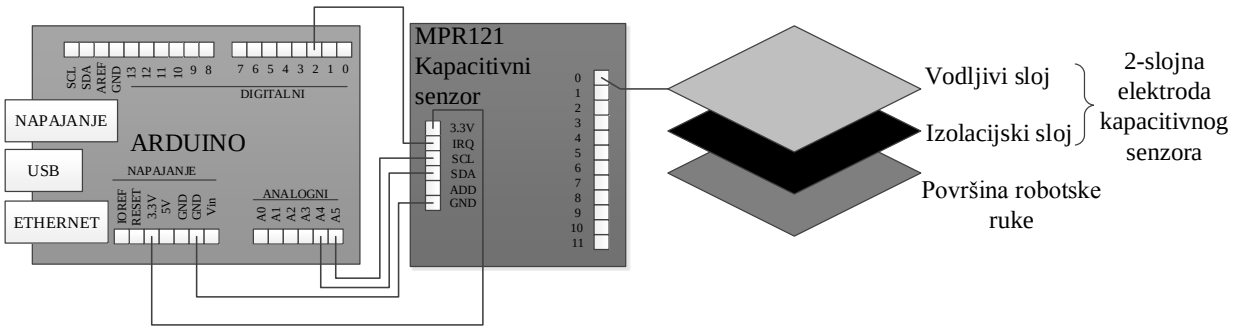

Slika 3.2. *Kapacitivni senzor*.

Elektroda kapacitivnog senzora je dvoslojna, mekana i fleksibilna „koža" robota. Oblikovana je prema konturama kućišta robota kako bi adekvatno mogla prekriti sve veće površine kojima bi robot potencijalno mogao dodirnuti čovjeka. Sastoji se od gornjeg sloja, koji je provodljiv, i izolacijskog sloja. Vodljivi dio spaja se ožičenjem na pločicu kapacitivnog

senzora. Kapacitivni senzor ne funkcionira ispravno kada su prisutne smetnje različitih električnih polja i zbog toga se izolacijskim slojem odvaja od kućišta robota.

Senzorski dio na robotu sastoji se od dvanaest elektroda sa zasebnom kalibracijom za svaku elektrodu. Na temelju kapacitivnosti određuju se pragovi aktivacije senzora, i to za blizinu (eng. *proximity*) i za dodir. Pragove je vrlo važno ispravno postaviti kako bi se eliminirali šumovi i lažno pozitivne aktivacije senzora. Za svaku se elektrodu zasebno određuju pragovi aktivacije kako bi se svaki ulaz mogao mjeriti neovisno o drugima. Vrijednosti pragova kalibriraju se u skladu s oblikom, veličinom i vrstom elektrode. Također ovise o uvjetima u radnoj okolini samog senzora – vlazi, nečistoćama, itd.

Promjena u kapacitivnosti na elektrodi senzora mjeri se u senzorskom sklopu MPR 121. Arduino upravljački sklop obrađuje izmjerene podatke uz pomoć razvijenog algoritma (*Algoritam 3.1*). Kada se podaci obrade, šalje se adekvatna poruka na računalo koje upravlja robotom. Za komunikaciju između Arduino upravljačkog sklopa i računala upotrebljava se TCP komunikacijski protokol.

Algoritam 3.1. *Kapacitivni senzor.*

Parametri:

$K=\{K_0, K_1, K_2,\ldots K_{12}\}$ – izmjerene vrijednosti na elektrodama

A, B – moguća djelovanja robota

PD – prag dodira

PB – prag blizine

Algoritam:

```
početak
K=ulaz
automatska kalibracija() //za određivanje početnih parametara
PD=auto + PD_korisnika
PB=auto + PB_korisnika
dok jevezačiniti  //beskonačna petlja dok postoji veza s računalom
K=ulaz
ako jeK(0)≥ PB tada
blizina()
za svaki i od 1 do 12
ako jeK(i)≥ PD tada
dodir(i)
šalji podatke()
kraj
```

Po površini robotske ruke raspoređene su sve elektrode senzora (*Slika 3.3*). U teoriji idealan raspored elektroda po zastupljenosti tj. prekrivenosti površine nije moguć zbog specifičnosti konture robota.

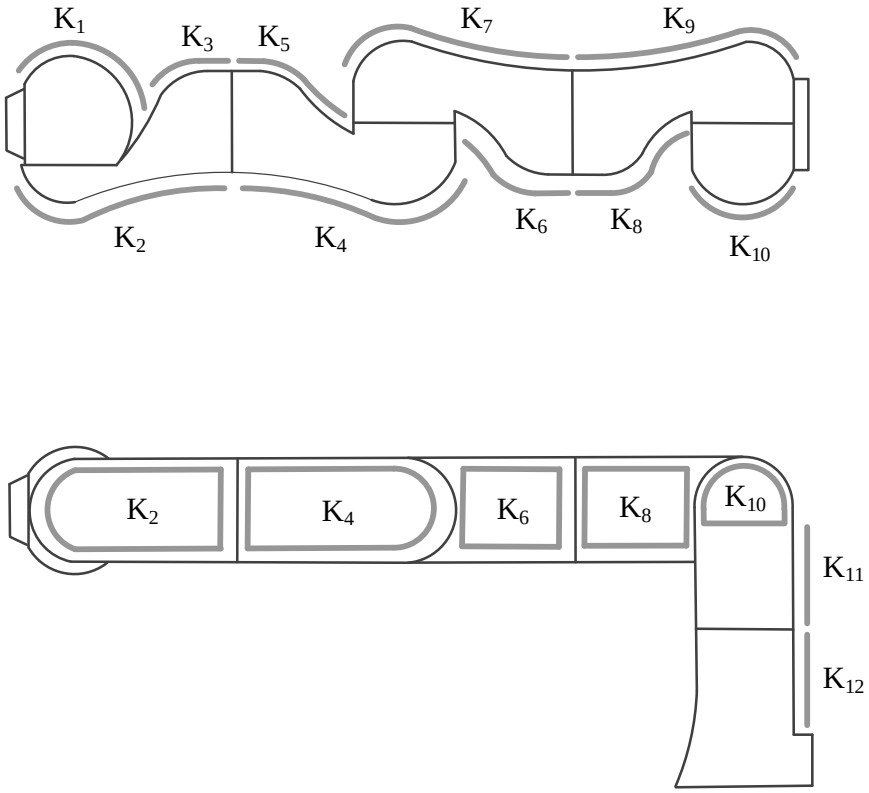

Slika 3.3. *Robotska ruka s elektrodama kapacitivnog senzora*.

3.1.2. Robot

Kuka LWR4+ lagana robotska ruka četvrta je generacija robota originalno razvijenog u DLR-u (Njemački svemirski centar) s ciljem laganog manipulatora s visokim omjerom nosivosti prema težini. Kinematska redundantnost ruke, sa sedam stupnjeva slobode, slična je ljudskoj ruci jer omogućava promjenu konfiguracije ruke, pritom zadržavajući položaj i orijentaciju završne prirubnice ruke. Svaki zglob sadrži senzor za mjerenje momenta, cjelokupna elektronika (osim upravljačkog računala) ugrađena je u ruku i gdje god je to bilo moguće, primjenom lakih materijala i modernih metoda optimizacije, smanjivana je masa robota. Senzori momenata smješteni u svakom od sedam zglobova, detaljan dinamički model, mogućnost upravljanja stanjima i brzi ciklusi servo-upravljanja, zajedno sa snažnim pogonom i laganom konstrukcijom omogućavaju aktivno prigušivanje vibracija kako bi se postigla visoka kvaliteta gibanja (točnost putanja, ponovljivost) [76]. Nadalje, naprednom

elektronikom omogućava se realizacija programirane popustljivosti, kako po osima robota, tako i kartezijske. Na taj se način može postići ponašanje robota kao sustava s prigušivanjem uz široki raspon dostupnih kontrolnih parametara. Upravljanje popustljivošću omogućava i ručno pokretanje robota, čime se otvara posve novo područje u interakciji ljudi i robota [77]. Sučelje robota s računalom FRI (eng. *fast research interface*) temelji se na jednostavnom UDP protokolu i korisniku omogućava upravljanje robotom i nadziranje njegovog stanja preko vanjskog PC uređaja. Pri uspostavljanju veze moguće je definirati vrijeme uzorkovanja između 1 i 100 ms. Naredbe gibanja kojima je za izvršavanje potrebno više od jedne milisekunde prije slanja obrađuju se i potom interpoliraju u kontroleru [77].

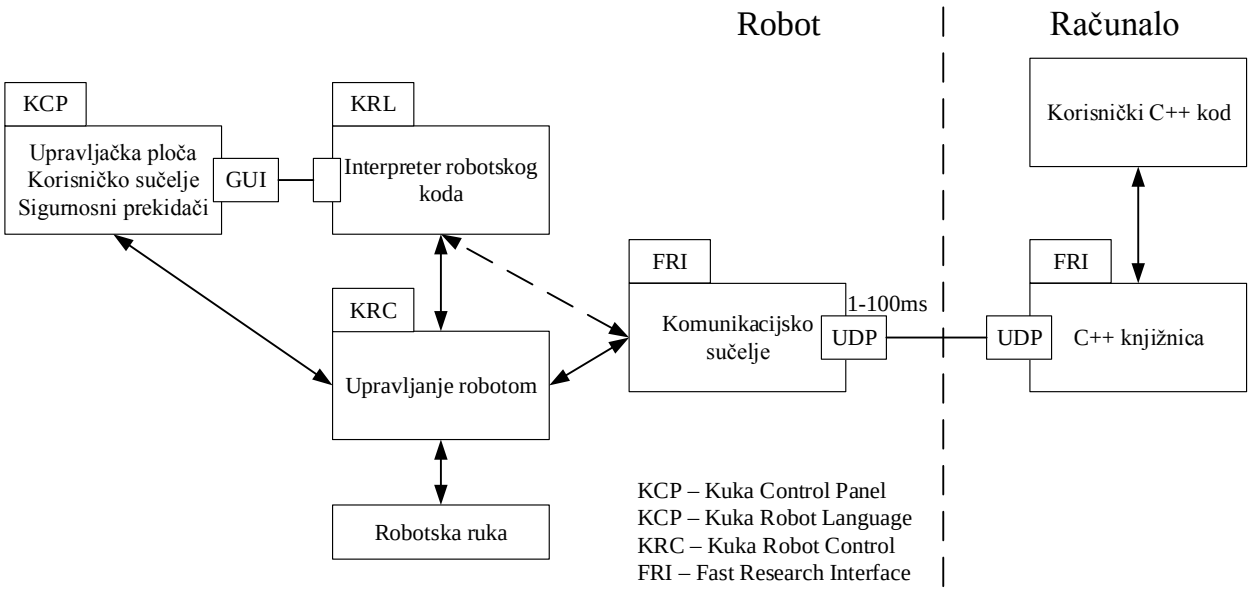

Slika 3.4. *FRI sučelje [34].*

Zaobljen oblik segmenata robotske ruke ne sadrži oštre rubove koji bi mogli ozlijediti čovjeka. Senzori detektiraju vanjske sile poput prepreka ili čovjeka. Robotska ruka je relativno male mase (16 kg) i u upravljačkoj jedinci je definirano ograničenje maksimalne dinamičke snage (80 W). Ove karakteristike čine LWR sigurnim suradnikom, bilo za dodavanje dijelova ljudima ili za držanje dijelova dok ljudi obavljaju operacije na njima.

Za interakciju s čovjekom i okolinom potrebno je odrediti veličine vanjskih sila koje se primjenjuju na robotsku ruku. Robotska ruka opremljena je senzorima momenata u svakom zglobu koji daju vrijednosti u obliku vektora momenata $\boldsymbol{\tau}$. Ti su senzori neovisni jedan o drugome. Vektor momenata $\boldsymbol{\tau}$ sastoji se od dviju komponenata:

$$\boldsymbol{\tau} = \boldsymbol{\tau}_{int} + \boldsymbol{\tau}_{ext}\,, \qquad (3.2)$$

gdje $\boldsymbol{\tau}_{int}$ predstavlja unutarnje komponente vektora momenata uslijed mase članaka i dinamičkih parametra i $\boldsymbol{\tau}_{ext}$, koji predstavlja momente uslijed utjecaja vanjskih sila. Na temelju poznatih parametra robotske ruke vrijednost $\boldsymbol{\tau}_{int}$ računa se unutar upravljačke jedinice i oduzima od izmjerenih momenata $\boldsymbol{\tau}$ te ostaje vrijednost momenata $\boldsymbol{\tau}_{ext}$. Kako bi se mogao izračunati vektor sila $\boldsymbol{F}_{ext}$ s kartezijskim komponentama, potrebno je transformirati $\boldsymbol{\tau}_{ext}$ uz pomoć Jacobijeve matrice $\boldsymbol{J}$ i matrice položaja zglobova $\boldsymbol{q}$ [78]. Odnos između vanjske sile $\boldsymbol{F}_{ext}$ i momenata uzrokovanih vanjskom silom $\boldsymbol{\tau}_{ext}$ dan je formulom:

$$\boldsymbol{\tau}_{ext} = \boldsymbol{J}(\boldsymbol{q})^T \boldsymbol{F}_{ext}. \tag{3.3}$$

3.2. Klasifikacija taktilnog podražaja

Cilj klasifikacije je tumačenje taktilnih senzacija. Klasifikacija je identificiranje u koju kategoriju nova taktilna senzacija spada, na temelju dodira s robotom i kapacitivnim senzorom. Klasifikacija se dijeli u tri glavne kategorije koje sadrže moguće interakcije robota s okolinom i čovjekom:

- opažanje sudara
- aktivni kontakt
- radne operacije.

Prva kategorija, opažanje sudara, definira neočekivani kontakt između čovjeka i robota. To znači da se čovjek i robot međusobno ometaju prilikom rada. Taktilnim senzacijama i reaktivnim djelovanjem omogućava se sigurnost čovjeka u takvim slučajevaima. Druga kategorija, aktivni kontakt, bavi se očekivanim dodirom čovjeka i robota. Fizički kontakt između čovjeka i robota primjenjuje se kao komunikacijski kanal. Dodirom se obavlja vođenje robota po prostoru i izdavanje raznih naredbi. Treća kategorija, radne operacije, predstavlja djelovanja robota s ciljem izvršavanja specifičnih dijelova zadataka. Svaka klasa se s obzirom na svoje specifičnosti dalje dijeli u potkategorije koje podrobnije opisuju interakciju.

Kako bi se mogla napraviti klasifikacija, potrebno je identificirati elemente na kojima se klasifikacija zasniva i definirati metriku. Osnovni elementi iz kojih se izvode sve vrijednosti parametara dijele se u tri glavne skupine:

- kapacitivnost
- sile
- pokret.

Potrebno je dodijeliti značenje aktivacije pojedinim kapacitivnim senzorima. Primjerice prilikom rada više osoba može se dogoditi da se sudare rukama ako rade nešto na zajedničkom radnom prostoru. Ali ako nas netko potapša po ramenu, velika je vjerojatnost da želi pridobiti našu pozornost ili nam ukazati na nešto – puno veća nego da je došlo do neželjenog sudara. U skladu s time treba dodijeliti različite mogućosti tumačenja aktivnosti senzora i s obzirom na ostale senzorske podatke dodijeliti im značenje.

S obzirom na vrstu, senzore ćemo podijeliti u dvije kategorije:

- I. vrste – kontaktni senzori – služe samo za određivanje prisutnosti čovjeka tj. potencijalnog sudara
- II. vrste – služe za interpretaciju želja korisnika – naredba, potvrda, zahtjev.

Tako primjerice rameni senzori služe samo kao senzori druge vrste. S druge strane, senzori na podlaktici svrstavaju se u senzore prve vrste.

Sljedeća stavka su mjerenja sila. Prilikom interakcije model treba voditi računa o vanjskim silama. Time je obuhvaćeno nekoliko elemenata. Prvi je razaznavanje događaja. Radi li se o sudaru s preprekom i javljaju li se samo sile prouzročene kolizijom uslijed brzine kretanja robota ili se radi o utjecaju čovjeka koji pokušava odgurnuti robota ili mu dodijeliti novi zadatak. Zbog toga treba odrediti pragove vanjskih sila koje aktiviraju pojedine obrasce ponašanja.

Prostornim vođenjem vrha alata robotske ruke omogućava se direktno upravljanje robotom. Pokreti koje čovjek izvodi robotskom rukom vrlo su sadržajni jer se iz jedne kretnje može iščitati cijeli niz parametara pokreta – smjer, udaljenost, brzina, sila i drugi. Klasifikacijom parametara pokreta radi se razaznavanje taktilnih gesti, a time i izdavanje naredbi (prihvat, odlaganje, zaustavljanje itd.) i oblikovanje trajektorija.

3.2.1. Opažanje sudara

Sudar predstavlja neželjeni udar jednog tijela o drugo, u ovom slučaju robotske ruke koje se kreću po prostoru s preprekom. Prepreka može biti bilo koji objekt ili čovjek u radnom području robota koji sprječava kretanje robota. Problem formulacije detekcije sudara ovisi o ulaznim parametrima, ali i o željenim izlaznim stanjima. Najjednostavnija formulacija izlaznih stanja je razlučivanje na stanja da/ne kao odgovor modela je li došlo do sudara. Iz sigurnosnih razloga u skladu s time nužno je zaustavljanje autonomnog kretanja robota u trenutku sudara.

Uz aspekt sigurnosnog zaustavljanja autonomnog kretanja moguće je prilikom sudara promijeniti i režim upravljanja robotskom rukom. Obilježje lagane robotske ruke je što može raditi u dva režima upravljanja – kruto izvođenje kretanja kao klasična robotska ruka i realizacija programirane popustljivosti. Ovisno o parametrima sudara, odlučuje se o daljnjem režimu rada robota.

Na temelju stanja ulaznih senzora treba klasificirati o kakvoj se vrsti prepreke radi te koja je željena reakcija robota (*Tablica 3.1*). Ulazna stanja predstavljaju aktivaciju kapacitivnog senzora i vrijednost vanjske sile $\boldsymbol{F}_{ext}$ koja djeluje na robotsku ruku. Vrsta prepreke može se razdijeliti na sudar s čovjekom i sudar s objektom. Željena reakcija robota uvijek je inicijalno zaustavljanje kretanja, no u slučaju velike vanjske sile i promjena režima rada u popustljivo kretanje. Zato se postavlja pitanje na koji iznos vanjske sile se mijenja način rada robota te ruka postaje popustljiva. Oba navedena mehanizama detekcije sudara koristite se pragom koji bi trebao biti dovoljno malen da bi se omogućile brze reakcije tj. osjetljivost, ali i dovoljno velik da se ne može aktivirati uslijed mjernih pogrešaka sustava.

S obzirom na iznos vanjske sile, podražaje možemo svrstati u dvije kategorije:

- kada sila prelazi prvi prag $\boldsymbol{F}_{T_1}$ (koji služi za eliminaciju šumova mjerenja), ali je ispod drugog praga – ovi događaji nam govore da je došlo do sudara;
- iznad drugog praga $\boldsymbol{F}_{T_2}$– ovi događaji nadilaze silu čistog sudara te ukazuju i na prisutnost dodatne vanjske sile, primjerice čovjeka koji pokušava odgurnuti robota.

Tablica 3.1. *Klasifikacija sudara.*

Aktivacija kapacitivnog senzora I. vrste	Vanjske sile		Prepreka	Reakcija
	$\boldsymbol{F}_{T_1} \leq \boldsymbol{F}_{ext} < \boldsymbol{F}_{T_2}$	$\boldsymbol{F}_{T_2} \leq \boldsymbol{F}_{ext}$		
x			čovjek	zaustavljanje
x	x		čovjek	zaustavljanje
x		x	čovjek	popustljivost
	x		objekt	zaustavljanje
		x	čovjek	popustljivost

*x – zadovoljeni uvjet.

3.2.2. Aktivni kontakt

Aktivnim kontaktom čovjeka s robotom čovjek može prenijeti svoju namjeru robotu. Pretpostavka je da se klasifikacijom parametara kontakta može razlučiti namjera pozicioniranja robotske ruke te izdavanje različitih naredbi robotu gestama. Upotrebom intuitivnih gesti za programiranje robota olakšava se programiranje robota. Intuitivnim sučeljem omogućava se programiranje stvarnih složenih zadataka na temelju neverbalne komunikacije. Cilj je omogućiti korisniku upravljanje robotom jednostavnim vođenjem po prostoru ili izdavanje određenih naredbi kratkim brzim pokretima, i to kroz fizičku interakciju – dodir. Geste su ciljane radnje korisnika kojima se pozivaju naredbe. Pristup s gestama ima glavni nedostatak što je potrebno znati geste. To zahtijeva kognitivno viši nivo od primjerice odabira iz izbornika te povećava i rizik odabira pogrešne naredbe. No taj se nedostatak može smanjiti ili u potpunosti eliminirati ako su geste intuitivne.

Definicija geste prema rječniku hrvatskoga jezika [14] glasi:

- pokret udova ili tijela (lica i sl.) kojim se izražava neka misao ili osjećaj ili se popraćuje govor
- *preneseno značenje:* ono što je rečeno ili učinjeno, obično kao formalan znak nakane ili odnosa prema tome.

Geste se tumače kao uređeni nizovi pojedinih segmenta kretanja, slično kao slaganje riječi u rečenici. Nizovi se sklapaju iz segmenata. Na temelju parametra registriranog podražaja mogu se razlučiti segmenti koji tvore geste. Kako bi se mogla protumačiti interakcija, treba napraviti analizu segmenata te na temelju sljedova klasificiranih segmenata razaznati koju je gestu korisnik upotrijebio.

Roboti (6/7 osni) su u mogućnosti razlučiti šest komponenata pokreta u prostoru – tri translacijske komponente i tri rotacijske komponente. Uz pomoć senzora sile i momenata moguće je razlučiti tri komponente sile i tri momenta oko pripadajućih osi. U radu će se upotrebljavati tri translacijske komponente pomaka i tri komponente sile. Geste možemo podijeliti u tri skupine. Prva skupina su geste koje se zasnivaju na registriranom pokretu. S obzirom na parametre pokreta, posebice pomak i brzinu, radi se klasifikacija. Druga skupina su stacionarne geste. Kod stacionarnih gesti ne postoji pomak u prostoru, već se temelje isključivo na primjeni vanjske sile. Posljednja skupina su naredbe zadane dodirom kapacitivnog senzora. Određene elektrode na stacionarnom dijelu ruke upotrebljavaju se za izdavanje različitih naredbi.

Klasifikacija aktivnog kontakta temelji se na mjerenim i izvedenim vrijednostima.

Mjerene vrijednosti:

- sila F,
- put s,
- vrijeme t.

Na temelju mjerenih vrijednosti mogu se izračunati izvedene vrijednosti:

- impuls sile I,
- brzina v.

Iznos brzine je derivacija puta po vremenu

$$v = \frac{ds}{dt}, \tag{3.4}$$

pri čemu s označava funkciju s(t) koja je prijeđeni put (dužina prijeđene putanje) do trenutka t, računajući od početnog trenutka ili položaja. Ono označava funkciju v(t), koja se može mijenjati od trenutka do trenutka, ali ne može biti negativna.

Impuls sile je fizikalna veličina definirana umnoškom sile $\boldsymbol{F}$ i vremena (t_1 i t_2 – vremena početka i kraja) tijekom kojeg je ta sila djelovala. Matematički se prikazuje kao

$$\boldsymbol{I} = \int_{t_1}^{t_2} \boldsymbol{F}\, dt. \tag{3.5}$$

Vanjska sila stvara akceleraciju i utječe na promjenu brzine kretanja dokle god djeluje. U jednom slučaju geste mogu biti interpretacije impulsa sile. Problem koji se javlja prilikom primjene impulsa sile je što je iznos jednak za veliku silu u kratkom vremenskom intervalu i manju silu u duljem vremenskom intervalu.

3.2.2.1. Segmentiranje

Kako bi se moglo klasificirati vrstu aktivnog kontakta, treba razložiti utjecaj vanjskih faktora na segmente u određenim razdobljima. Segmentiranje se obavlja s obzirom na brzinu kretanja kod kontakta s prostornim pomakom i s obzirom na silu kod kontakta sa stacionarnim položajem.

Jednostavan način segmentacije na temelju brzine je s obzirom na točku središta alata. Točka središta alata (*Slika 3.5*) ili TCP (eng. *Tool Center Point*) je točka koordinatnog sustava koji određuje matematička transformacija s obzirom na prirubnicu završnog članka robotske ruke. Zapisom trenutnog položaja robota u biti se zapisuje položaj te točke u prostoru.

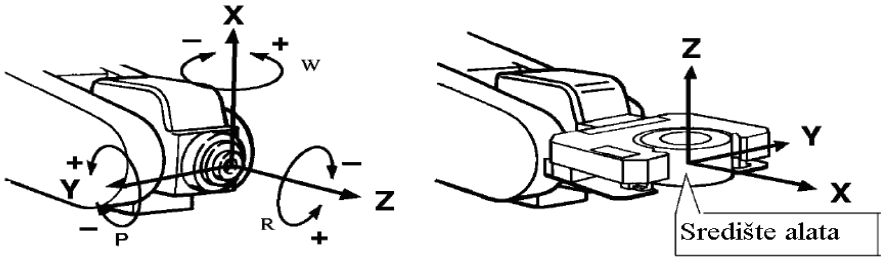

Slika 3.5. *Točka središta alata.*

Da bi se segment klasificirao kao pokret, mora imati određeni prag brzine kretanja. Početak vremenskog intervala kretnje započinje u trenutku kada brzina kretanja premaši određeni iznos. Prekid pojedinog segmenta nastaje kada apsolutna brzina kretanja padne ispod određenog iznosa.

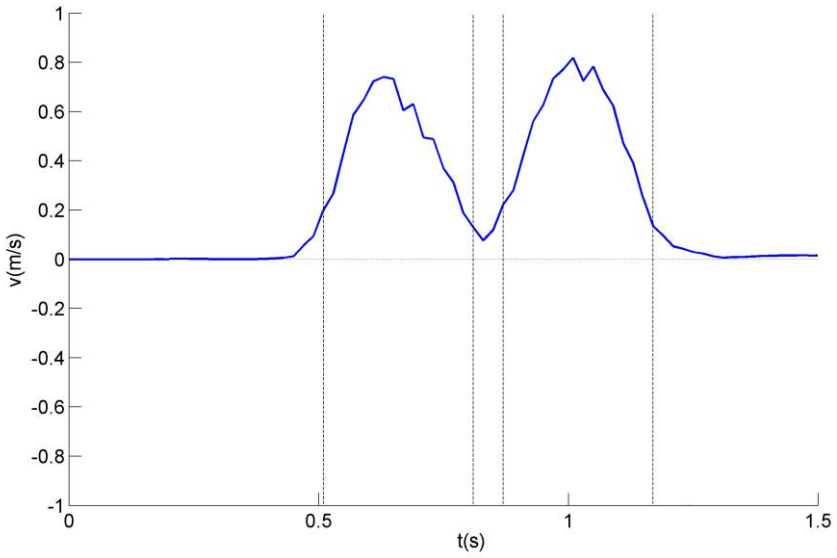

Slika 3.6. *Segmentacija na osnovi brzine.*

Sličan pristup primjenjuje se prilikom segmentiranja s obzirom na silu kod kontakta sa stacionarnim položajem. Kada vanjska sila premaši određeni prag, trenutak se registrira kao početak segmenta. Prekid segmenta nastaje kada vanjska sila padne ispod određenog iznosa.

3.2.2.2. Klasifikacija segmenata

U slučaju interpretacije pomaka klasifikacija se primarno obavlja na temelju brzine. Postoji jasna distinkcija na brze i spore pokrete, kao i nagle trzaje kojima se želi izdati određena naredba.

Podjela s obzirom na brzinu pokreta:

- brzo
- sporo
- trzaj.

Brzi i spori pokreti su u biti vođenje vrha robotske ruke kroz prostor od početka do kraja kretanja, dok je trzaj kratko i silovito usmjeravanje koje čovjek primjeni na robota i odgurne ga u željenom smjeru.

Za klasifikaciju smjera djelovanja upotrebljava se pomak. Budući da procjenjujemo smjer kretnje na temelju pomaka, kao smjer djelovanja upotrijebit ćemo pomak s obzirom na početno mjesto. Ako nisu vezane za kontekst ili značajke u prostoru, ljudima je teško percipirati kretnje ili sile u horizontalnoj ravnini s jasnom distinkcijom po kojoj su osi x ili y. Ako se mogu vezati za određeni objekt, rub ili stol, tek tada mogu imati pripadajuće značenje. U suprotnom su jednakovrijedne te se zbog toga komponente pomaka isključivo po osima x i y definiraju kao horizontalna kretnja. Parametri vezani za vertikalnu os z imaju jasnu distinkciju gore-dolje, te im se može dodijeliti posebno značenje, čak i bez kontekstualne informacije. S obzirom na spomenuta ograničenja, smjerove pomaka dijelimo u tri skupine:

- vertikalni pomak
- horizontalni pomak
- prostorni pomak.

Na temelju značajki brzine i smjerova kretnje, oblikuju se osnovni oblici pokreta tj. primitivne kretnje.

Tablica 3.2. *Osnovne kretnje.*

Sporo	horizontalno	SH
	gore	SG
	dolje	SD
	prostorno	SP
Brzo	horizontalno	BH
	gore	BG
	dolje	BD
	prostorno	BP
Trzaj	horizontalno	TH
	gore	TG
	dolje	TD
	prostorno	TP

U slučaju interpretacije u stacionarnom stanju klasifikacija se obavlja isključivo na temelju sile. S obzirom na iznos vanjske sile radi se podjela u dvije skupine, na mali i veliki iznos vanjske sile. Smjer vanjske sile određuje se na temelju vrijednosti komponenata sile F_x, F_y, F_z. Kao i kod smjerova pomaka, smjerove vanjske sile dijelimo u kategorije horizontalnog, vertikalnog i prostornog smjera. S obzirom na smjer i iznos vanjske sile, radi se klasifikacija u skupine osnovnih sila (*Tablica 3.3*).

Tablica 3.3. *Osnovne sile.*

Mala sila	horizontalno	FMH
	gore	FMG
	dolje	FMD
	prostorno	FMP
Velika sila	horizontalno	FVH
	gore	FVG
	dolje	FVD
	prostorno	FVP

Metrika i parametri potrebni za klasifikaciju segmenata u grupe osnovnih kretnji i osnovnih sila definirat će se eksperimentalno u poglavlju 3.4.

3.2.2.3. Geste

Interakcija s gestama primjenjiva je utoliko ukoliko je jednostavno korisniku naučiti moguće naredbe i njima se koristiti. Postoje različite varijante gesti, a uključuju sve elemente od statičnih dijelova do kratkih silovitih pokreta. Kombiniranjem raznih elementarnih pokreta i sila kreiramo različite geste. Prvi korak je izgraditi temeljni set gesti pomoću elemenata osnovnih kretnji i osnovnih sila.

Set gesti gradi se ulančavanjem elemenata. Potom se uređenim lancima pridaje značenje u obliku geste koja aktivira određeno djelovanje robota. Primjerice sekvenca dvaju segmenata BD (brzo dolje) i BG (brzo gore) naznačuje odlaganje predmeta na plohu. No samo ulančavanje segmenata je nedostatno za opisivanje gesti. Uz osnovne pokrete i osnovne sile treba uvesti i komponentu vremena. Vrijeme između dvaju segmenata, bilo kretanja ili stacionarne sile, također daje značenje gestama i povezanosti segmenata. Vremenski interval između dvaju segmenata dijelimo u dvije kategorije:

- KT – kratki vremenski interval
- DT – dugi vremenski interval.

Slika 3.1 prikazuje usporedbu različitih vremenskih intervala između dvaju segmenata. Usporedno je prikazan kratki vremenski interval a) s trajanjem 0,04 s i dugi vremenski interval b) u trajanju 0,74 s koji povezuju segmente. Ako vremenski interval između dvaju segmenata premašuje granice dugog vremenskog intervala, smatra se da dva segmenta nisu u korelaciji. Zbog toga se tada prekida lanac koji korisnik oblikuje iz različitih segmenata.

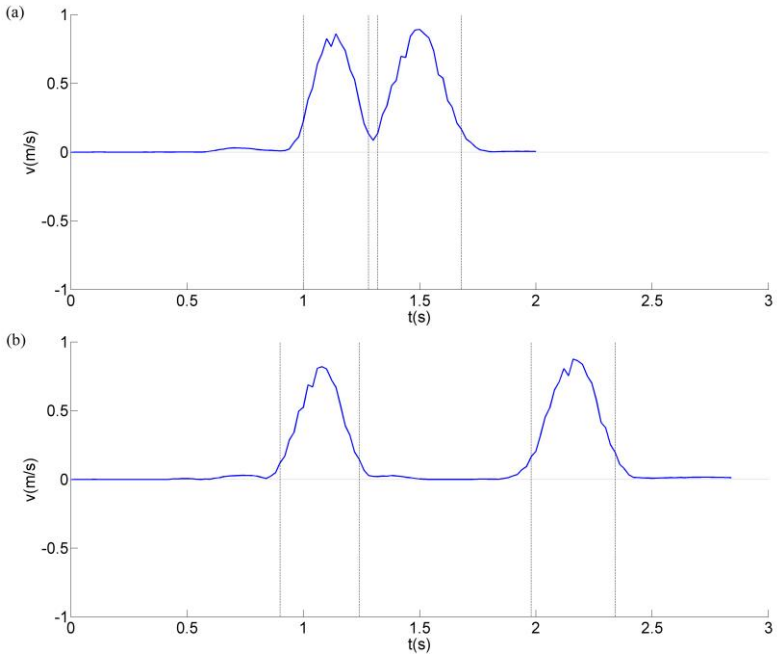

Slika 3.7. *Vremenski razmak između dvaju segmenata: a) kratki interval, b) dugi interval.*

Spore kretnje (SH, SG, SD i SP) i brze kretnje (BH, BG, BD i BP), ako se javljaju izolirano, upotrebljavaju se za oblikovanje putanja i prostorno vođenje robotske ruke od jednog mjesta rada do drugog.

Također, potrebno je omogućiti zadavanje nul-putanje, koja osigurava privremeno zaustavljanje robota tj. naredbe *wait* do trenutka kada korisnik ne primjeni dovoljnu silu za nastavak djelovanja. Pri izvođenju nul-putanje robot stoji na mjestu. Takav element može biti koristan kada robot pridržava određeni predmet dok korisnik obavlja operacije nad njim ili jednostavno čeka potvrdu korisnika da može nastaviti djelovanje.

Tablica 3.4. *Tablica osnovnih gesti.*

R.Br.	Kombinacija	Značenje
1.	SH	putanja/prostorno vođenje
2.	SG	putanja/prostorno vođenje
3.	SD	putanja/prostorno vođenje
4.	SP	putanja/prostorno vođenje
5.	BH	putanja/prostorno vođenje
6.	BG	putanja/prostorno vođenje
7.	BD	putanja/prostorno vođenje
8.	BP	putanja/prostorno vođenje
9.	TH	zahtjev operacije
10.	TP	zahtjev operacije
11.	FVD	odlaganje
12.	FVG	izuzimanje
13.	FVH	zahtjev operacije
14.	BD – KT – BG	odlaganje
15.	FMH – KT – FVG	nul-putanja do sile FVG
16.	FMH – KT – FVD	nul-putanja do sile FVD

Geste se dijele u dvije skupine – vezane za kontekst i nevezane za kontekst. Geste koje nisu vezane za kontekst ne moraju sadržavati popratne informacije. Primjerice gesta operacije odlaganja BD – KT – BG može se izvoditi bilo gdje u radnom prostoru i pri tome imati jednako značenje.

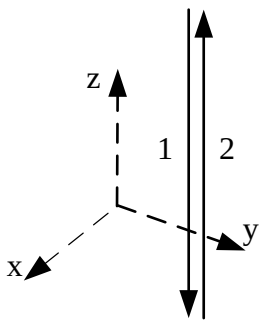

Slika 3.8. *Gesta odlaganja.*

Geste vezane za kontekst moraju biti popraćene određenim informacijama. Primjerice gesta zahtijeva operacije usmjeravanjem prema određenom cilju mora biti popraćena s postojećim

ciljevima u prostoru. Zbog toga je ovisna o kontekstu. Ako postoji cilj u smjeru koji se poklapa sa smjerom korisnika, tada i gesta ima pripadajuće značenje. U skladu s postojećim ciljevima u radnom prostoru definiraju se vektori ciljeva $\boldsymbol{v}_c$. Na temelju smjera kretanja koje je oblikovao korisnik definira se vektor korisnika $\boldsymbol{v}_k$ koji opisuje usmjeravanje. Ako se smjerovi vektora $\boldsymbol{v}_c$ i $\boldsymbol{v}_k$ poklapaju unutar određenih granica (*Slika 3.9*), gesta se tumači kao zahtjev operacije koja se obavlja na željenom cilju.

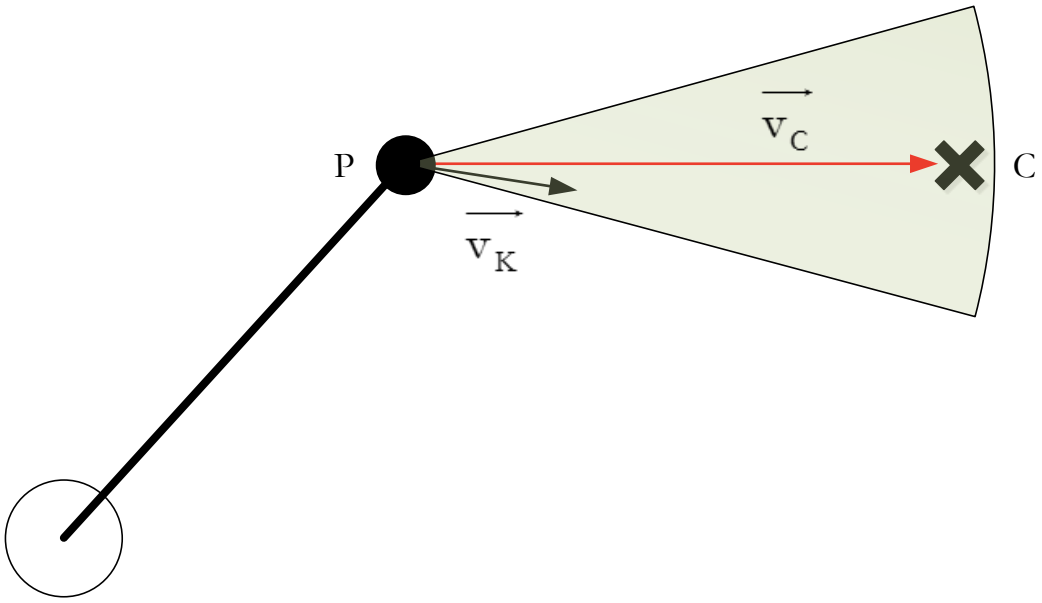

Slika 3.9. *Smjer korisnika i cilja.*

3.2.2.4. Kapacitivni senzor

Aktivni kontakt može se ostvariti i s elektrodama kapacitivnog senzora. Tada elektrode kapacitivnog senzora raspoređene po robotskoj ruci služe za interpretaciju želje korisnika – naredba, potvrda, zahtjev. U skladu s time treba dodijeliti različite mogućosti tumačenja aktivnosti senzora i s obzirom na ostale senzorske podatke dodijeliti im značenje.

U radu će se za izdavanje naredbi upotrijebiti dvije elektrode blizu bazi robota. Jedna elektroda (K12) nalazi se na stacionarnom dijelu, a druga (K11) na prvom pomičnom segmentu (*Slika 3.3*). Te dvije elektrode izabrane su zbog toga što je vjerojatnost slučajnog sudara s njim prilikom djelovanja robota izrazito mala.

Elektroda K12 ima funkciju izmjene režima rada robota između popustljivog i čvrstog načina djelovanja. Ta funkcija omogućava brzu promjenu prilikom rada, a zbog toga i mogućnost primjene ostalih elemenata aktivnog kontakta na samog robota. Kako korisnik ne bi morao biti u stalnom kontaktu s elektrodom, kada se aktivira određeni režim djelovanja, ostaje aktivan do ponovnog kontakta.

3.2.3. Radne operacije

Roboti nalaze široku primjenu u zadacima zavarivanja, izuzimanja, odlaganja, umetanja, bojenja, brušenja, glodanja i dr. Operacije predstavljaju djelovanje robota s ciljem izvršavanja specifičnih dijelova zadataka. S obzirom na moguće netočnosti sustava, ali i na nepotpune i netočne podatke o stanju okoline i radnog predmeta, javljaju se određene greške u radu. Primjerice prilikom operacije umetanja uslijed netočnosti u izradi ili u pozicioniranju dijelova, moguće je djelovati prevelikom silom i oštetiti dijelove ili elemente sustava. Primjena informacije dobivene dodirom u vidu sila omogućava izvođenje raznih operacija usprkos netočnostima. Tri izdvojene operacije su: hvatanje objekata, umetanje i bušenje.

Operacije hvatanja važna su komponenta pri manipulaciji dijelovima u ljudskoj okolini. Uslijed raznovrsnosti svakodnevnih predmeta i različitih okolina potrebne su robusne operacije hvatanja koje se mogu nositi s varijacijama oblika, veličine i položaja objekata [79]. Iako napredak raznovrsnih tehnologija povećava preciznost lokalizacije objekata, greške i netočnost robotske ruke prilikom pozicioniranja narušavaju učinkovitost hvatanja. Upotreba informacije dobivene dodirom u vidu sila omogućava robusnije operacije hvatanja objekata.

Prilikom operacija sklapanja, točnije umetanja, također se manifestiraju akumulirane greške cjelokupnog sustava. Upotrebom navođenja silom moguće je izvršiti operacije umetanja unatoč greškama sustava ili greškama inicijalnog pozicioniranja. Navođenje se temelji na parametrima položaja (x, y, z, ψ, θ, ϕ) i sile (F_x, F_y, F_z, M_x, M_y, M_z). Upravljačkim procesom obavlja se korekcija sile. Jednostavni primjeri uključuju umetanje osovine u provrt (eng. *peg in hole*), dok složeniji procesi uključuju i oscilacije u izvršnoj sili kako se dijelovi ne bi međusobno zaglavili.

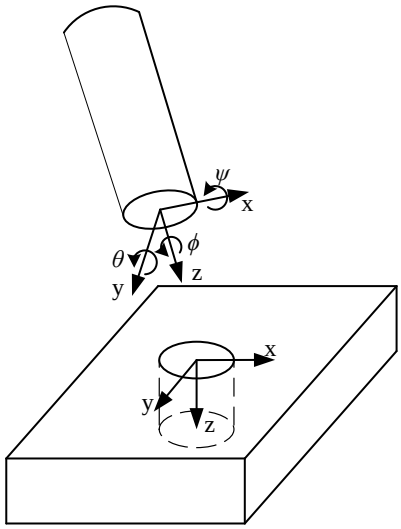

Slika 3.10. *Umetanje osovine.*

Operacije sklapanja su uglavnom vezane za industrijsku primjenu robota, no problemi koji se javljaju izvan industrijskog ograničenja također nalaze primjenu taktilne interakcije. Sličan problemu umetanja na temelju sile je i problem bušenja kosti u kirurškim aplikacijama. Prilikom same operacije bušenja treba djelovati određenom silom kako bi se ostvario adekvatan pomak. Kritična komponenta operacije je eliminacija prodora alata nakon probijanja kosti kao se ne bi oštetilo okolno tkivo. U trenutku prodora alata iznos sile naglo se mijenja (*Slika 3.11*). Upotrebom upravljačkih algoritama zaustavlja se proces bušenja u trenutku probijanja svrdla.

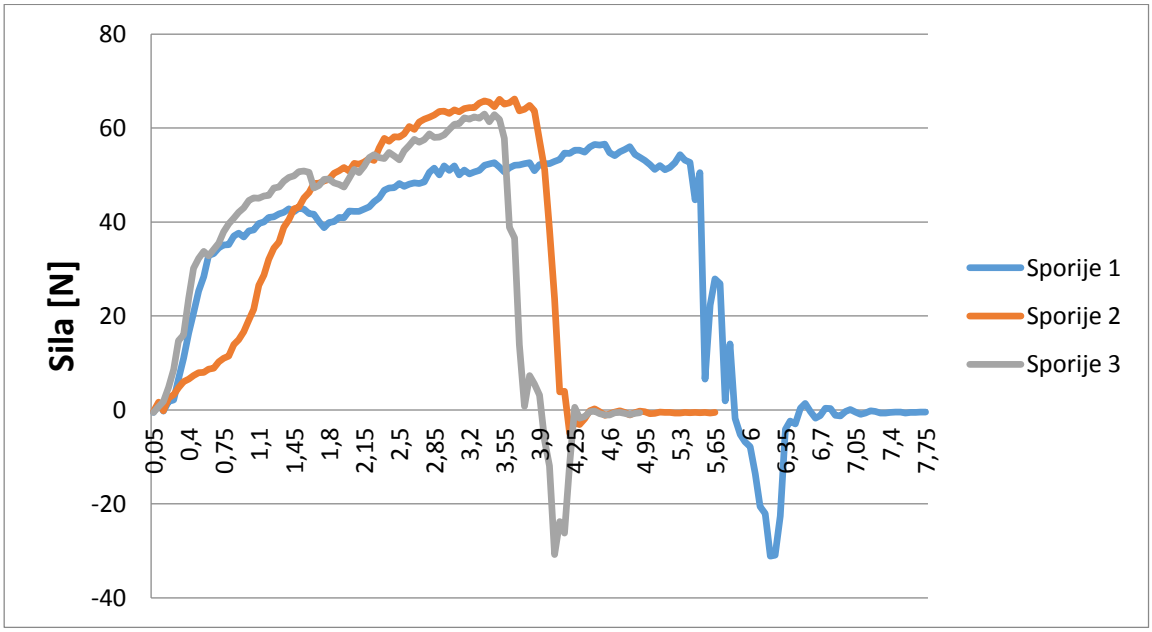

Slika 3.11. *Sile uslijed bušenja kosti kirurškom bušilicom.*

3.3. Višekriterijska interpretacija prostora

Robot se mora kretati i djelovati u svojoj radnoj okolini. Radna okolina sadrži statičke i dinamičke elemente u prostoru. Robot mora biti sposoban izbjegavati prepreke na siguran i efikasan način, pritom motreći na promjenjivost svoje okoline te se prilagođavati novim zahtjevima. Taj se proces uvelike oslanja na senzoriku i zaprimanje podataka o stanjima senzora kako bi robot stvorio sliku svijeta oko sebe i samog sebe s trenutnim položajem i konfiguracijom u takvom prostoru. Robot gradi sliku radnog prostora na temelju taktilnih podražaja. Kroz interakciju s okolinom i čovjekom oblikuje se višekriterijska interpretacija međudjelovanja, koja osim fizičkih komponenata uključuje i utjecaj konfiguracije radnog prostora.

Višekriterijska interpretacija služi kao metoda pohrane interakcije robota s čovjekom, ali i s okolinom. Klasifikacijom taktilnih podražaja na temelju kapacitivnog senzora, sile i prostornog položaja razaznaju se elementi interakcije. Potom se razlučeni elementi zapisuju zajedno sa svojim prostornim značajkama na različite načine u skladu s vrstom interakcije. Tako se definira višekriterijska interpretacija radnog prostora u kojoj postoji distinkcija između različitih elemenata. U skladu s distinkcijom prostor se segmentira na nekoliko cjelina. Slijedom se uvode slojevi pojedinih elemenata prostora na temelju kojih se gradi kompletna slika.

Višekriterijska interpretacija prostora inicijalno se oblikuje u Kartezijevu prostoru. Kada se na Kartezijev prostor primjene ograničenja vezana za dijelove prostora koje robot može doseći s obzirom na kinematska ograničenja, on postaje radni prostor W (eng. *workspace*).

$$W \subset \mathbb{R}^3. \tag{3.6}$$

Radni prostor robotske ruke opisuje se kao dio prostora koji dijelovi ruke mogu dohvatiti kroz sve moguće položaje zglobova. Definiran je geometrijom robotske ruke i ograničenjima zglobova [16].

U radu se robotska ruka promatra kao ravni štap koji se u odnosu na nepomičnu ravninu x-y giba rotirajući oko osi z. Štap je ujedno promjenjive dužine, dakle vrh se translacijski može približiti ili udaljiti od središta rotacije. Radni prostor tako prikazanog robota je

$$W \subset \mathbb{R}^2. \tag{3.7}$$

Radni prostor je ograničen na površinu radnog stola

$$W_S \subset W, \tag{3.8}$$

predviđenu za izvršavanje operacija i interakciju s čovjekom.

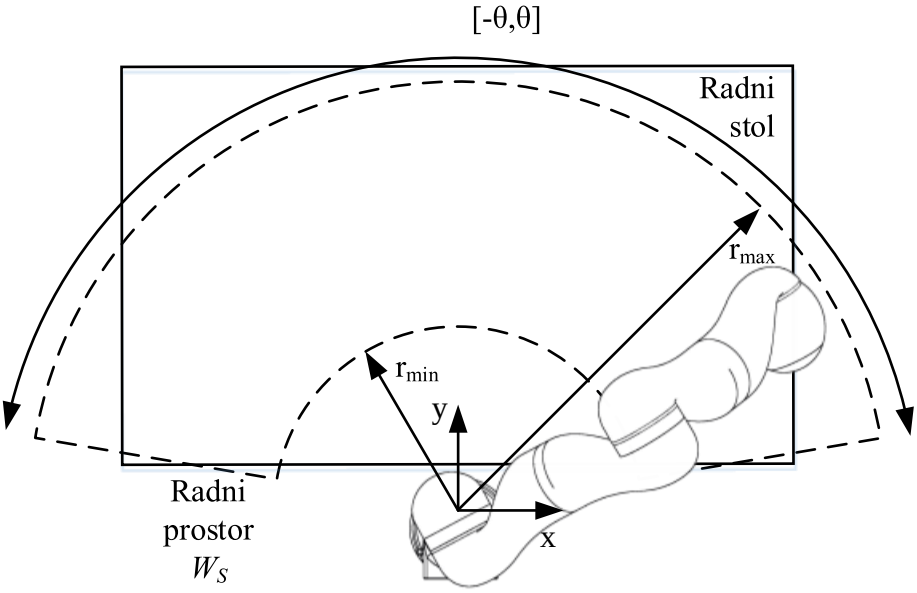

Slika 3.12. *Radni prostor* W_S.

3.3.1. Slojevi višekriterijske interpretacije prostora

Višekriterijskom interpretacijom prostor se dijeli na temeljne komponente:

- ciljevi
- prepreke – objekti
- kolizije s ljudima
- putanje.

Svakom se sloju s obzirom na prisutnost pripadajućih komponenata pridjeljuju vrijednosti, i to u intervalu [0,1]. Rubni slučaj kada vrijednost segmenta prostora iznosi jedan, naznačuje sigurnu prisutnost pripadajuće komponente unutar sloja. Suprotno tome, rubni slučaj kada vrijednost segmenta prostora iznosi nula naznačuje potpuno odsustvo komponente. Primjerice u sloju prepreka zauzeti dijelovi prostora u kojem se sigurno nalazi objekt u prostoru poprimaju vrijednost jedan. Nezauzeti dijelovi prostora poprimaju vrijednost nula.

3.3.1.1. Ciljevi

Ciljevi su područja izvođenja raznih operacija tj. lokacije djelovanja. Predstavljaju primjerice mjesto izuzimanja ili odlaganja, obavljanja raznih radnji itd. Prostor ciljeva

$$P_C = \{C_1,\ C_2, \ldots C_n\}, \qquad (3.9)$$

sadrži sve definirane ciljeve i njihove prostorne položaje (*Slika 3.13*). Ovisno o složenosti operacije, pojedini cilj sastoji se od jednog ili više prostornih položaja potrebnih za izvođenje ciljane operacije. Uza zapis koja se operacija obavlja, sadrži i popratne informacije o parametrima brzine i sila izvođenja. Prostor ciljeva mora biti definiran kao podskup radnog prostora

$$P_C \subset W_S, \tag{3.10}$$

kako bi robot mogao dosegnuti sve ciljeve u prostoru.

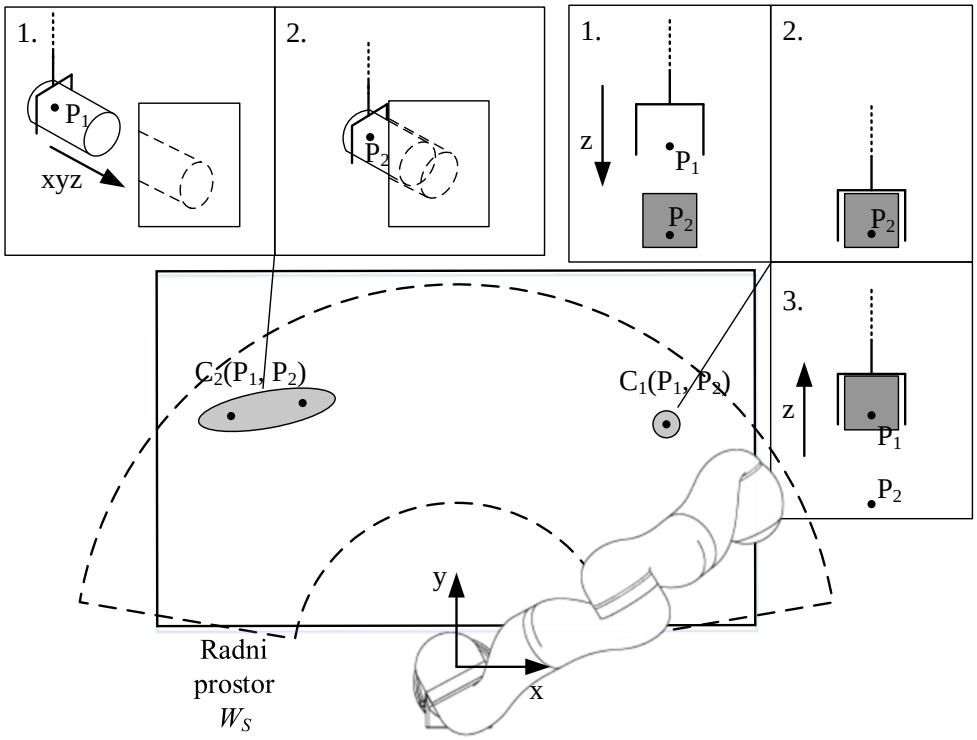

Slika 3.13. *Prostor ciljeva.*

3.3.1.2. Prepreke

Prepreka je objekt, stvar, radnja ili stanje koje uzrokuje opstrukciju. Pri tome su fizičke prepreke (poput ograda, objekata ili drugih robota) koje blokiraju djelovanje u ovome sloju prepoznate kao prepreke i predstavljaju područje nedostupno za robota. Prostor prepreka

$$P_O = \{O_1,\ O_2, \ldots O_n\}, \tag{3.11}$$

sadrži sve definirane i detektirane prepreke i njihove prostorne položaje (*Slika 3.13*). Prostor prepreka definira se kao podskup radnog prostora

$$P_O \subset W_S, \tag{3.12}$$

zato što su prepreke izvan radnog prostora irelevantne za kretanje robota.

Prepreke se upisuju u prostornu mapu prilikom kolizije s objektima opažanjem sudara. Kako bi se položaj prepreke mogao točno zapisati, potrebno je odrediti točku dodira robota i prepreke. Likar i Žlajpah u svojem radu [80] predlažu model na temelju kojeg je moguće procijeniti točku kontakta na robotskoj ruci. Pojednostavljenjem i prilagodbom tog modela omogućena je lokalizacija sudara s preprekom. Na temelju $\boldsymbol{\tau}_{ext}$ koji predstavlja momente uslijed utjecaja vanjskih sila određuje se koji su sve zglobovi pod utjecajem vanjske sile. Na temelju opterećenih zglobova određuje se na kojem je članku došlo do kontakta. Potom se lokalizirana prepreka zapisuje u prostor prepreka P_O.

Također, u prostor prepreka mogu se zapisivati druge robotske ruke i manipulatori koji zadiru u radni prostor. Na temelju komunikacije i izmjene informacija o položaju prostor koji zauzimaju predstavlja se kao prepreka.

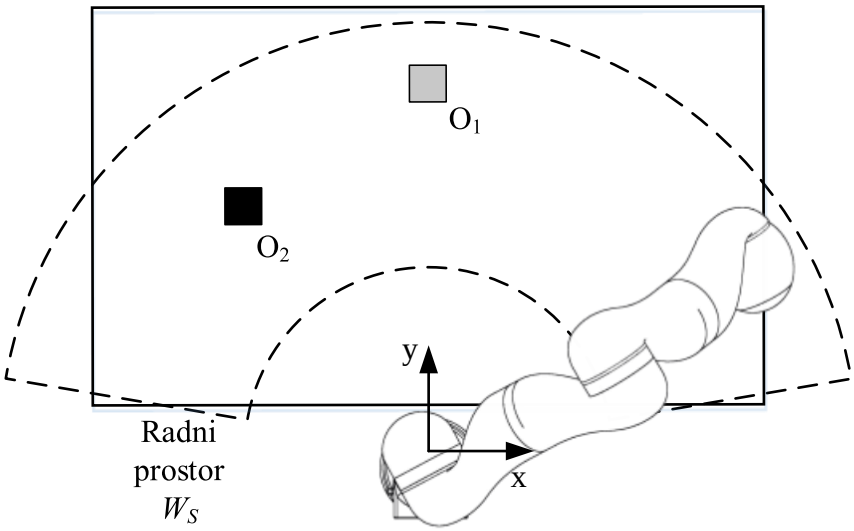

Slika 3.14. *Prostor prepreka.*

3.3.1.3. Ljudi

Drugi element prostornih prepreka je definiranje interakcije tj. sudara s ljudima. Prostor sudara s ljudima

$$P_L = \{L_1,\ L_2, \ldots L_n\}, \tag{3.13}$$

sadrži detektirane kolizije i njihove prostorne položaje. Prostor interakcije s čovjekom definira se kao podskup radnog prostora

$$P_L \subset W_S, \tag{3.14}$$

zato što se interakcija ne može odviti izvan radnog prostora robota.

Lokalizacija sudara s čovjekom, tj. prostorni položaj čovjeka određuje se pomoću elektroda kapacitivnog senzora. S obzirom na položaj robota u prostoru, pripadajuće kinematske transformacije i aktivnost elektroda precizira se točka kontakta. Potom se ona zapisuje u prostor sudara s ljudima P_L.

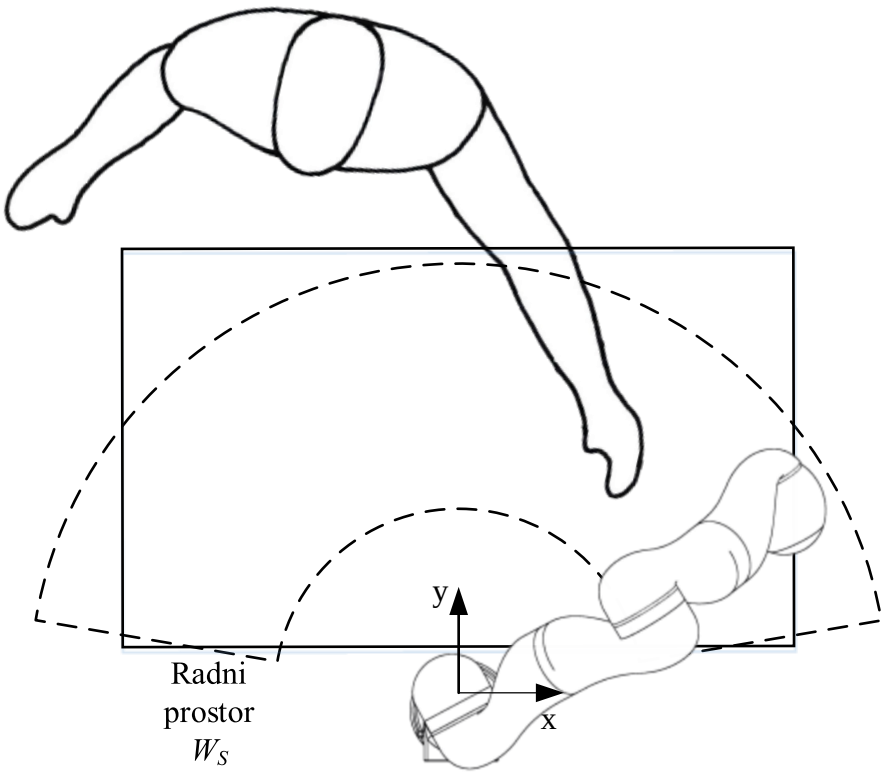

Slika 3.15. *Prostor sudara s ljudima.*

3.3.1.4. Putanje

Posljednji element su pohranjene putanje koje potom robot upotrebljava za kretanje od jednog cilja do drugog. Pri gibanju robota točka središta alata mijenja svoj položaj, a niz točaka položaja pritom čini trag koji nazivamo putanjom ili trajektorijom. Prostor putanja

$$P_T = \{T_1,\ T_2, \ldots T_n\}, \qquad (3.15)$$

sadrži sve definirane putanje i zapis niza njihovih prostornih položaja (*Slika 3.16*). Putanja $T \in P_T$ može se definirati u tri različita oblika:

- pravocrtna putanja
- korisnička putanja
- generirana putanja.

Pravocrtne putanje su korisniku najjednostavnije za vizualizaciju. Kretanje je pravac te je unaprijed vidljivo postoje li potencijalne kolizije. Putanje naučene od korisnika pohranjuju se u obliku niza točaka kroz prostor kako bi se kretanje moglo replicirati. Takve putanje osiguravaju prilagodbu zahtjevima korisnika uz prednost što korisnik planira kretanje koje izbjegavaju kolizije. Pretpostavka je da će vođenje prethodnim tzv. „provjerenim" putovima osigurati trajektoriju bez kolizije, ali radi se i dodatna provjera. Pretražuje se prostor stanja i ako ne postoji prethodno definirana putanja, bilo linearna ili korisnička, koja omogućava kretanje bez kolizije, stvara se nova. Putanje generirane pretraživanjem prostora stanja uz pomoć algoritama prostornog planiranja u biti predstavljaju najkraći put do željene točke bez kolizije.

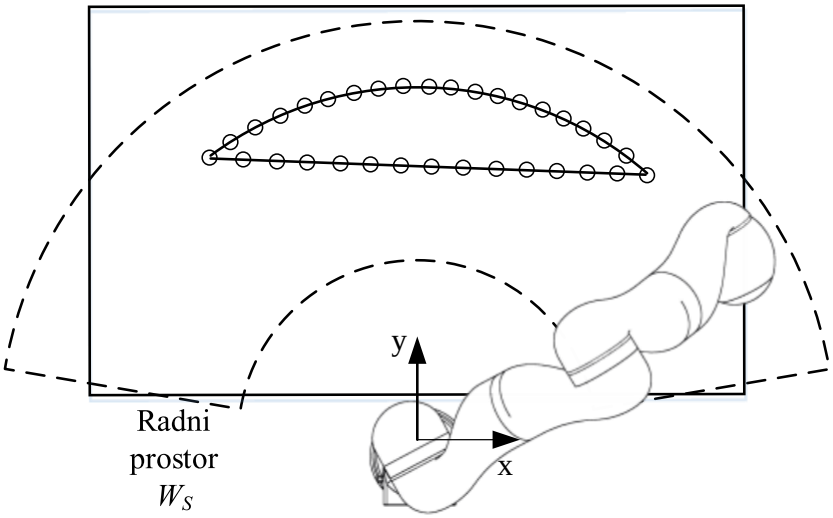

Slika 3.16. *Prostor putanja.*

3.3.2. Vremenska komponenta i preklapanje slojeva

Predloženom višekriterijskom interpretacijom radnog prostora načinjena je distinkcija između različitih slojeva, od kojih svaki predstavlja određenu vrstu interakcije i kretanja po prostoru. Uz samu podjelu uvodi se i vremenska komponenta smanjenja intenzivnosti određenih polja prostora. Time bi se za odabrane slojeve uveo određen povrat u neutralna stanja kako bi se osigurao rad u dinamičkim okolinama. Pretpostavka je da je vremenska domena drukčija za svaki sloj. Primjerice djelovanje čovjeka ne može se svesti u istu vremensku domenu s fiksnim preprekama u prostoru. Zbog toga će se pokušati predstaviti različite vremenske domene kretanja ljudi i promjene položaja objekata. Slojevi se dijele kako bi omogućili razliku u evaluaciji kretanja te dodijelili različite vremenske domene obama slojevima. Ljudi

nisu stacionarni te se njihov položaj u prostoru neprekidno mijenja. Zbog toga se s vremenom postupno smanjuje vrijednost $L_n \in P_L$. U konačnici se nakon određenog vremena u potpunosti briše iz prostorne mape. Položaj objekata je u pravilu mnogo trajniji u prostoru te se vremenska domena za objekte $O_n \in P_O$ razlikuje od vremenske domene P_L.

Vremenske domene slojeva P_O i P_L možemo usporediti s kratkoročnim pamćenjem i zaboravljanjem tijekom vremena. Kod kratkoročnog pamćenja ljudi se lakše sjećaju posljednjih elemenata u usporedbi s elementima koji su im prethodili. Provedenim eksperimentom [81] uspostavljena je veza pamćenja nekoliko jednostavnih elementa u ovisnosti o vremenu. Pamćenje elemenata smanjuje se kroz vrijeme na oko 50 % nakon 6 sekundi, a zaboravljanje je gotovo potpuno nakon 18 sekundi (*Slika 3.17*).

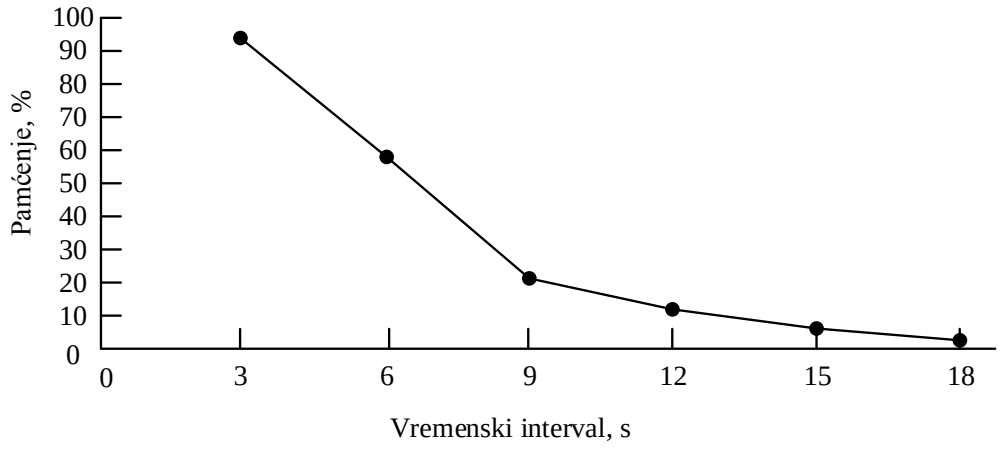

Slika 3.17. *Kratkoročno pamćenje – zaboravljanje [81].*

Slično procesu ljudskog pamćenja, simulira se proces zaboravljanja za elemente višekriterijske interpretacije prostora. Tako se pridaje veće značenje elementima što su bliže sadašnjem trenutku. U početnom trenutku $t = 0$ elementu $L \in P_L$ ili $O \in P_O$ dodjeljuje se vrijednost jedan. Zatim se vrijednost elementa postupno smanjuje s prolaskom vremena određenim intenzitetom, ovisno o tome kojem sloju pripada. Pridružene funkcije su linearne i svakom se sloju pridružuje specifični koeficijent smjera k_L i k_O.

Funkcija za prostor sudara s ljudima glasi

$$L(t) = k_L t + 1, t \in \left[0, \frac{1}{k_L}\right], \tag{3.16}$$

a za prostor prepreka (objekata)

$$O(t) = k_O t + 1, t \in \left[0, \frac{1}{k_O}\right]. \tag{3.17}$$

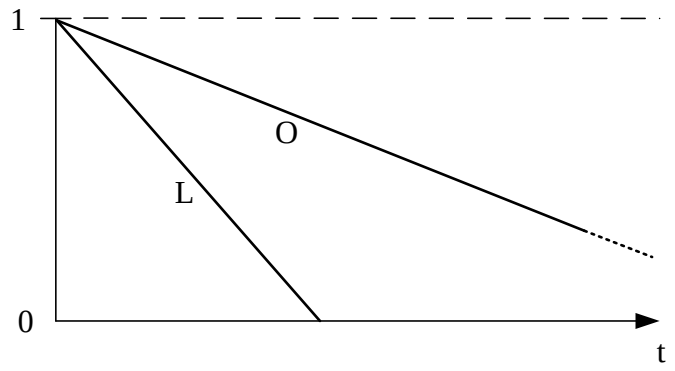

Slika 3.18. *Linearna karakteristika funkcija smanjenja intenziteta.*

Kako bi se mogle nastaviti operacije u definiranom višekriterijskom prostoru, potrebno je objediniti sve prostorne elemente. Potrebne su informacije o prostornim položajima ciljeva, putanjama između njih te, u konačnici, opstrukcija prilikom kretanja robota. Zbog toga se radi preklapanje slojeva u jedinstveni prostor

$$P_{VK} = P_C \cup P_O \cup P_L \cup P_T. \qquad (3.18)$$

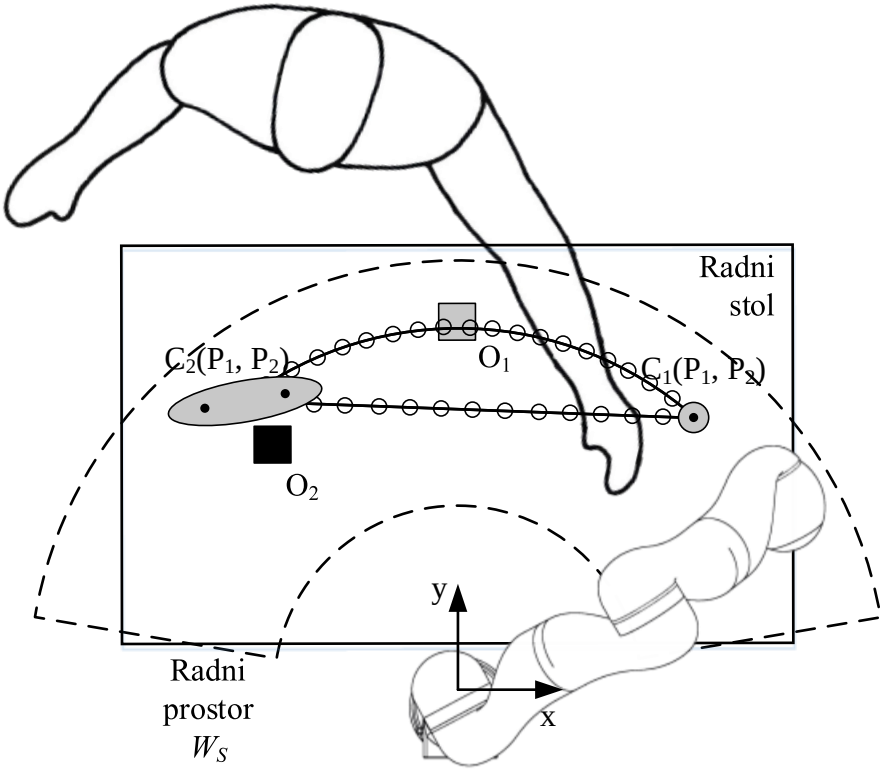

Slika 3.19. *Preklapanje slojeva.*

3.3.3. Konfiguracijski prostor

Kartezijev prostor, u kojem se inicijalno oblikuje višekriterijska interpretacija prostora, ljudima je smislen zbog toga što predstavlja stvarni prostor direktno te ga je lako protumačiti i vizualizirati. No za robota on nije idealan. Zbog toga treba upotrijebiti konfiguracijski prostor (eng. *configuration space*) – *C*. Konfiguracijski prostor je set svih mogućih konfiguracija robota. Svaka konfiguracija robota određena je položajima svih zglobova robota – kutnim za rotacijske zglobove i dužinom za translacijske zglobove. Zbog toga je dimenzija konfiguracijskog prostora jednaka broju stupnjeva slobode kretanja koji odgovara broju zglobova *n*

$$C \subset \mathbb{R}^n. \tag{3.19}$$

U ovom slučaju, s obzirom na to da se robotska ruka promatra kao ravni štap koji se u odnosu na nepomičnu ravninu x-y giba rotirajući oko osi z, konfiguracijski prostor

$$C \subset \mathbb{R}^2, \tag{3.20}$$

koji se sastoji od dva zgloba, zapravo je polarni koordinatni sustav.

Kako bi se prostorno planiranje moglo temeljiti na konfiguracijskom prostoru, treba napraviti pretvorbu komponentna iz Kartezijeva sustava u konfiguracijski sustav (*Slika 3.20*). Uz pomoć trigonometrijskih transformacija povezujemo Kartezijeve koordinate (x, y) i polarne koordinate (r, θ):

$$r = \sqrt{x^2 + y^2} \tag{3.21}$$

$$\theta = \tan^{-1}\left(\frac{y}{x}\right) \tag{3.22}$$

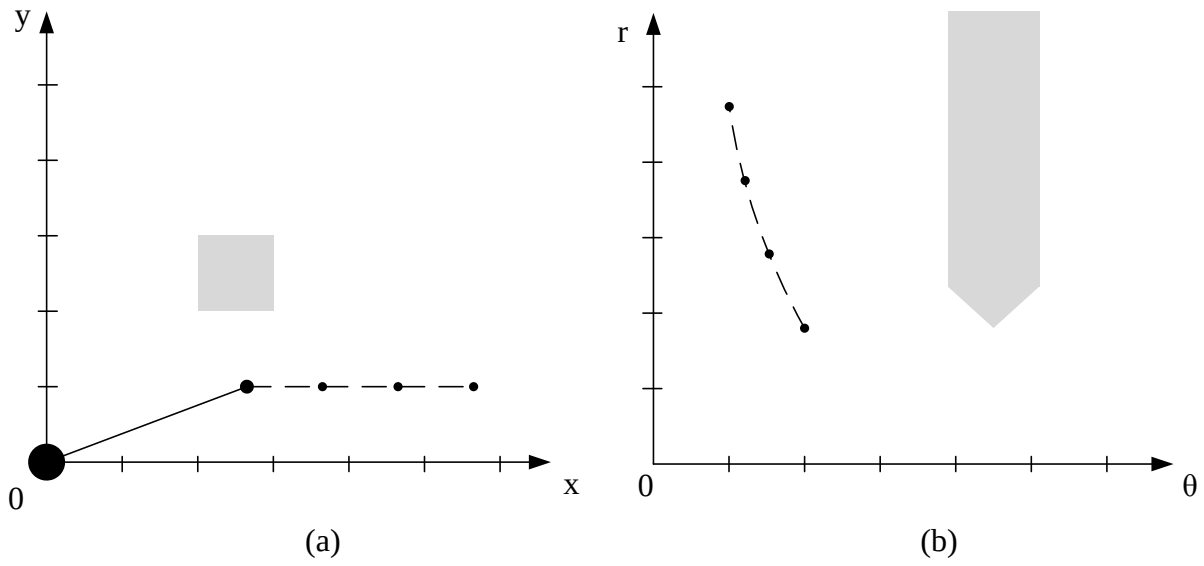

Slika 3.20. *Prikaz u Kartezijevu a) i konfiguracijskom b) koordinatnom sustavu.*

3.3.4. Prostorno planiranje

Izbjegavanje sudara, u odnosu na opažanje sudara, radi se nakon što je otkriven mogući sudar. Mogući sudari ovise o obliku i veličini prepreka i robota, kao i o položaju i kretanju robota. Kada su u radnom prostoru robota prisutne prepreke, planirane putanje moraju biti sigurne kako bi se izbjegli sudari. Planiranje putanje u radnom prostoru robota jedna je od važnih komponenata sustava upravljanja robotom. Kako bi se robot mogao samostalno kretati kroz prostor, potrebno je implementirati prostorno planiranje.

Problem prostornog planiranja vezan je za prostornu mapu i putanje u prostoru. Planiranje pokreta može se formulirati na učinkovit način koristeći se konceptom konfiguracijskog prostora. Planiranje kretanja temelji se na izradi plana na temelju poznatih podataka o radnoj okolini. Te informacije mogu biti unaprijed poznate ili se mogu oblikovati kako se robot kreće po radnom prostoru. Definiranjem višekriterijske interpretacije radnog prostora načinjena je distinkcija između objekata u okolini, čovjeka, samog robota te putanja robota. U vidu primjene procesa planiranja u realnom vremenu potrebne su simplifikacije procesa i mogućnosti optimalnog pretraživanja prostora stanja.

Planiranje putanje može biti zahtjevno s obzirom na algoritam i diskretizaciju prostora koja se upotrebljava. Za problem planiranja postoje razni algoritmi te svaki ima svoje prednosti, nedostatke i primjenjivost na određene probleme. Tehnike rješenja uključuju egzaktne, probabilističke i heurističke metode.

Za pristup planiranju potrebno ga je prilagoditi rješavanju na računalu, tj. treba izabrati metodu za diskretiziranje prostora. Implementirana diskretizacija prostora temelji se na podjeli prostora u pravilno raspoređenu četvrtastu mrežu. Takva razgradnja ima prednost jer je iznimno jednostavna za implementaciju.

S obzirom na željenu veličinu polja odabiru se različite veličine diskretizacije prostora. Ukupni radni prostor koji treba diskretizirati ograničen je dvama parametrima:

$$r \in [300,700], \tag{3.23}$$

$$\theta \in [-80,80]. \tag{3.24}$$

Na temelju ograničenja ukupna dimenzija radnog prostora iznosi 400 mm i 160°. Taj prostor treba zapisati u diskretnu mrežu. S obzirom na željenu konačnu veličinu polja predlaže se nekoliko veličina diskretizacije (*Tablica 3.5*, Tablica 3.6). *Tablica 3.5* prikazuje podjelu u različiti broj polja s obzirom na kutni položaj robotske ruke θ. S obzirom na to da se radi o polarnom koordinatnom sustavu, isti kutni pomak na različitom radijusu r ne daje iste vrijednosti pomaka u Kartezijevu prostoru. Zbog toga je prikazan pomak u Karetzijevu prostoru na tri različita radijusa: maksimalnom d_{r_max}, minimalnom d_{r_min} i srednjem d_{r_sr}.

Tablica 3.5. *Diskretizacija kuta.*

broj polja	50	100	200
$\Delta\theta$, °	3.2	1.6	0.8
d_{r_max}	39.09	19.55	9.77
d_{r_min}	16.75	8.38	4.19
d_{r_sr}	27.92	13.96	6.98

Broj polja u koja se dijeli prostor s obzirom na radijus prilagođen je kako bi u Kartezijevu prostoru veličinom približno odgovarao podjeli po kutu. S obzirom na razlike kod različitih radijusa kao referentan radijus odabran je pomak na srednjem radijusu d_{r_sr}.

Tablica 3.6. Diskretizacija radijusa.

broj polja	15	30	60
Δr, mm	26.67	13.33	6.67

Time je definirana osnovna podjela u diskretizirani prostor triju različitih dimenzija: 15 x 50, 30 x 100 i 60 x 200 (*Slika 3.21*). S obzirom na položaje elemenata u prostoru oblikuju se vrijednosti polja mreže.

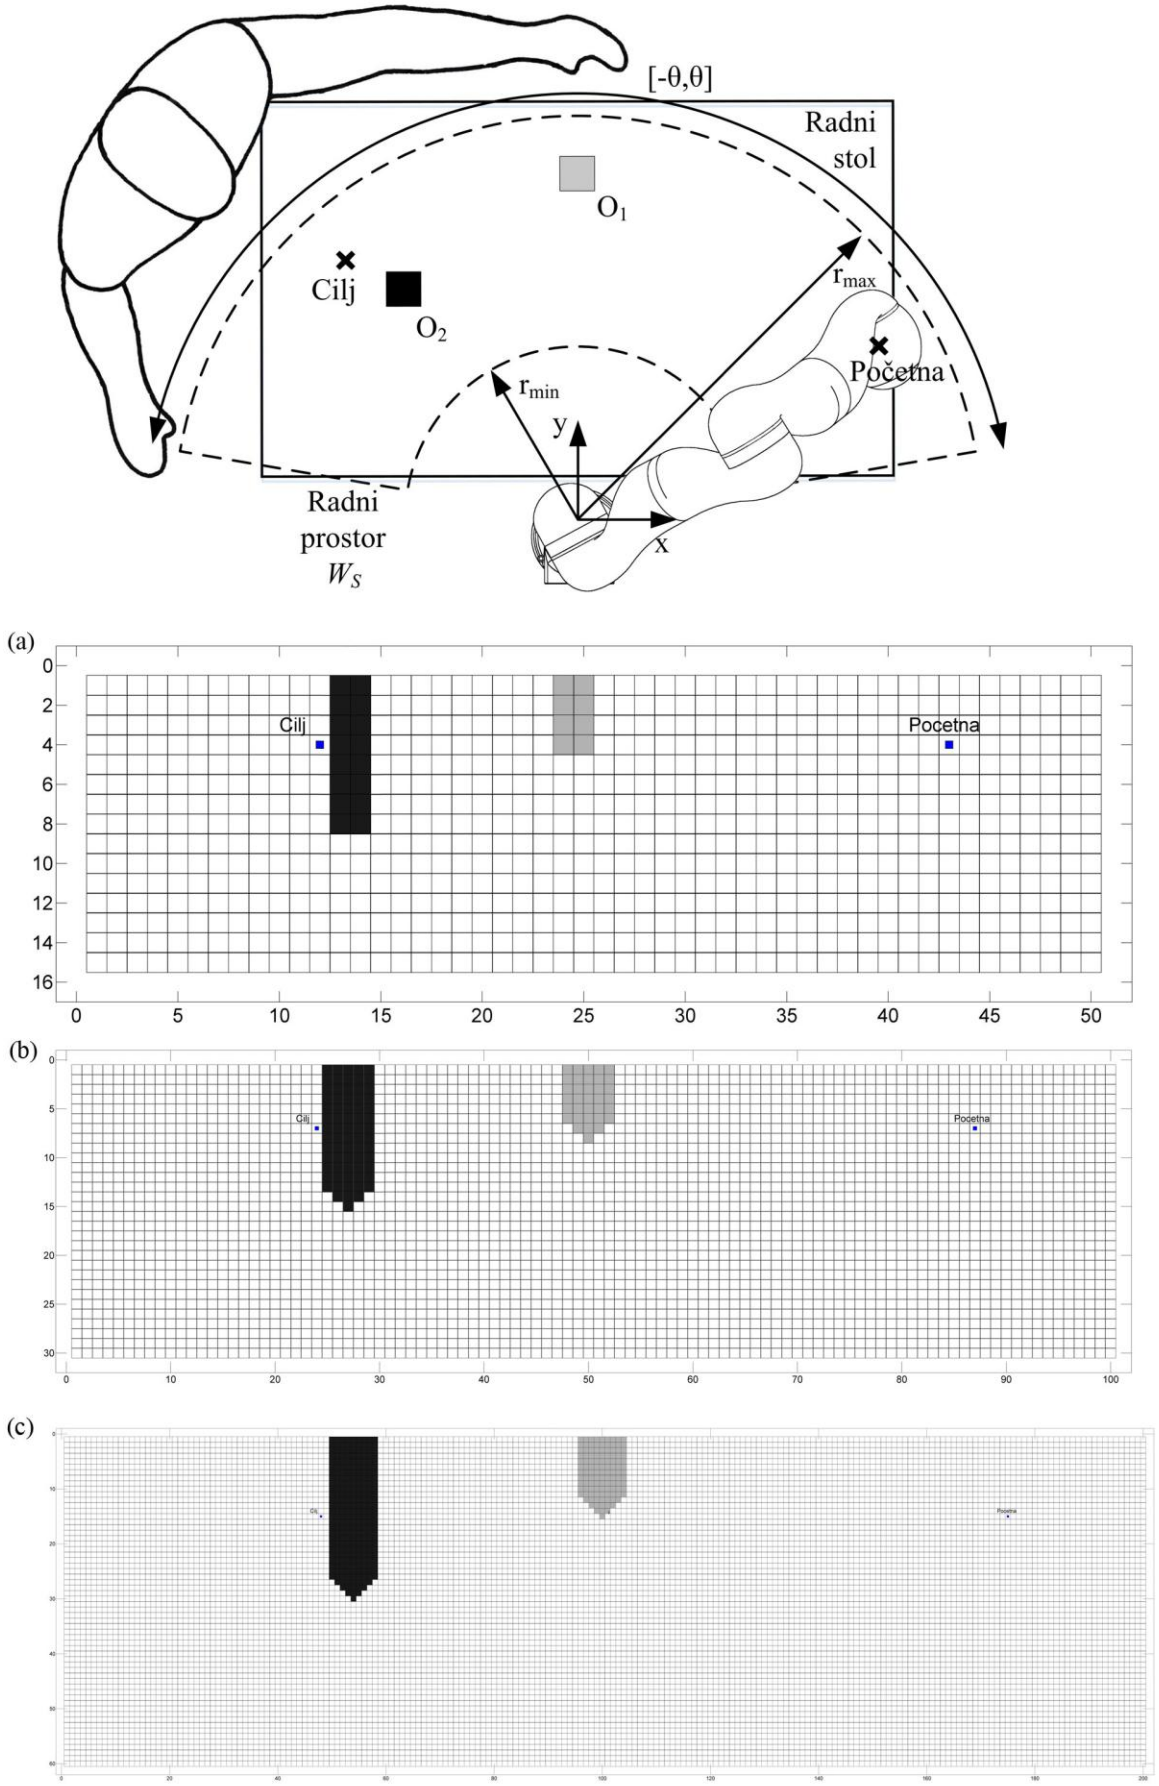

Slika 3.21. *Diskretizacija prostora: a) 15 x 50, b) 30 x 100, c) 60 x 200.*

Na temelju presjeka svih slojeva određuju se poželjni položaji i putanje robota u prostoru. Pretpostavka je da će vođenje prethodnim tzv. „provjerenim" putovima osigurati trajektoriju bez kolizije, ali provodi se dodatna provjera. Ta nam provjera omogućava da simuliramo kretanje robotske ruke po prethodnim trajektorijama te obavimo provjeru kolizije ruke s objektima ili ljudima.

U slučaju da je na temelju provjere donesen zaključak da prethodne putanje nisu pogodne za kretanje, potrebno je pretraživanje prostora kako bi se pronašla adekvatna putanja. Planiranje u konfiguracijskom prostoru se potom pomoću algoritama za planiranje kretanja svodi na problem pronalaženja najkraćeg puta u grafu. Najjednostavniji oblik pretraživanja prostora je neinformirano pretraživanje. Tom se metodom pretražuje prostor bez utjecaja gdje se nalazi cilj. Zbog toga metode ne pronalaze nužno optimalni put (najkraći). Neinformirano pretraživanje predstavljaju pretraživanje u širinu (eng. *breadth-first search*) i u dubinu (eng. *depth-first search*) [82]. Informirano pretraživanje odabire naredno polje pomoću funkcije koja sadrži informaciju o prostoru. Informirano pretraživanje predstavljaju A*, D* i *Greedy search* algoritmi. Najpoznatiji oblik najbolje informiranog pretraživanja je A*, koji je implementiran u radu. A* je heuristički algoritam koji ima široku primjenu zbog svoje efikasnosti. A* se koristi listom otvorenih polja – polja koja su već posjećena, ali nisu obrađeni svi njihovi susjedi, i zatvorenih polja – polja koja su posjećena i kojima su obrađeni svi njihovi susjedi. A* se koristi funkcijom evaluacije

$$f(x) = g(x) + h(x), \tag{3.25}$$

gdje je g(x) cijena puta od polaznog polja do polja x, a h(x) je procijenjena cijena najjeftinijeg puta od polja x do ciljnog polja.

Prvi korak u metodi je odrediti moguće smjerove pomaka u diskretiziranom prostoru. Svako polje u prostoru graniči s osam susjednih polja. Četiri polja nalaze se horizontalno i vertikalno s obzirom na polja, a preostala četiri nalaze se na dijagonalama. S obzirom na mogućnosti prijelaza u susjedno polje princip kretanja u prostoru dijeli se na četiri moguća smjera (*Slika 3.22* a) i osam mogućih smjerova (*Slika 3.22* b).

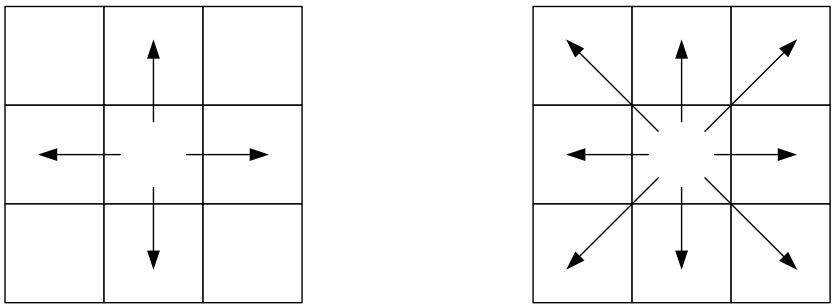

(a) (b)

Slika 3.22. *Mogući smjerovi kretanja: a) četiri smjera, b) osam smjerova*.

Slika 3.23 prikazuje diskretizirani prostor stanja (30 x 100) i različite putanje od početnog do željenog konačnog stanja. Putanja (*Slika 3.23* a) prikazuje planirano kretanje po prostoru u četiri smjera, a putanja (*Slika 3.23* b) kretanje u osam smjerova.

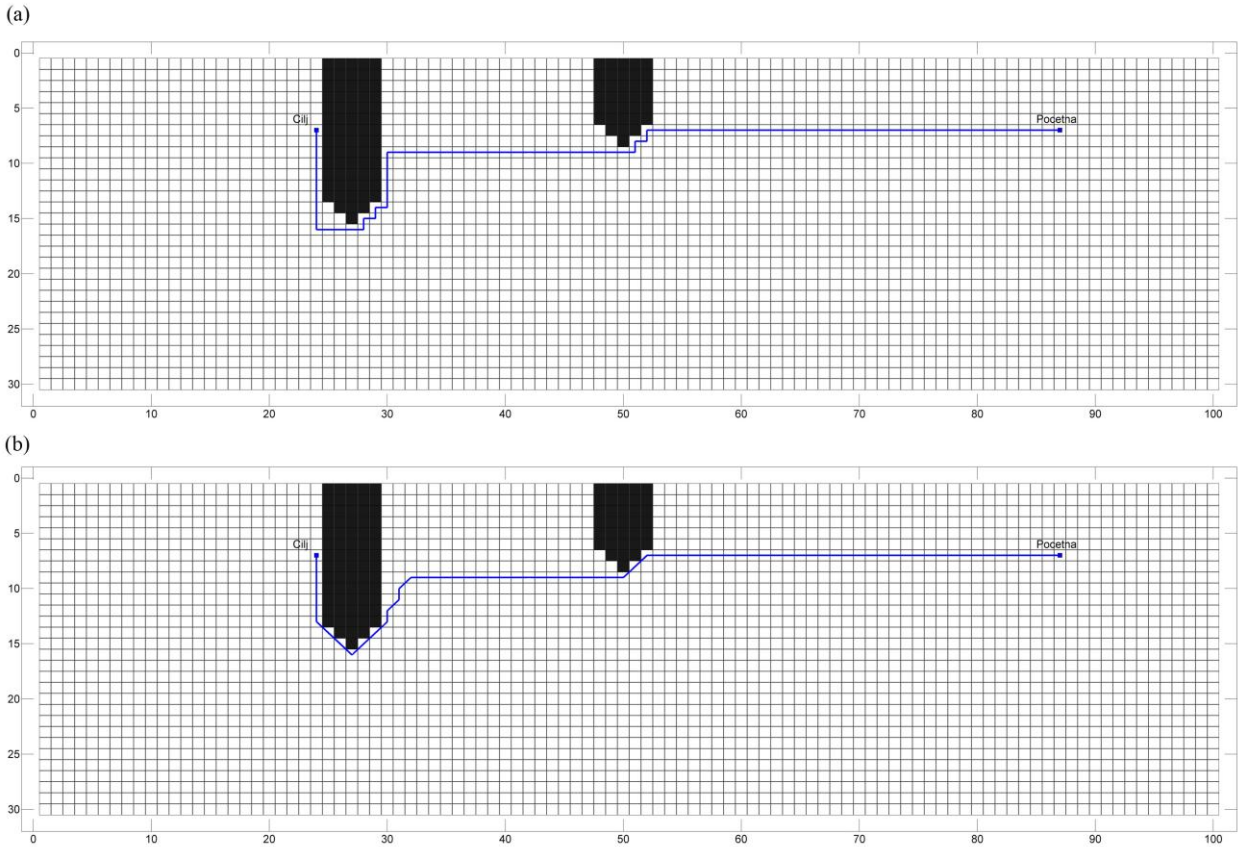

Slika 3.23. *Putanja a) u četiri smjera kretanja, b) osam smjerova kretanja*.

Prepreke u prostoru su raznih intenziteta s obzirom na vjerojatnost da se nalaze u radnom prostoru. Iterativnim povećanjem pragova zanemaruju se prepreke koje imaju manju vjerojatnost da još uvijek postoje. U prvom slučaju počinje se od visoko postavljenog praga koji za obradu ostavlja samo segmente s visokim faktorom sigurnosti tj. područja poželjnih

vođenja. Ako se ne pronalaze zadovoljavajuća rješenja, prelazi se na niži prag, gdje se jedan dio prepreka s nižom vjerojatnosti isključuje iz prostora stanja. Potom se proces ponavlja iterativno. Na temelju filtriranih vrijednosti oblikuju se putanje kretanja robotske ruke. Parametar praga utječe na profil brzine koja je razmjerna njegovom iznosu. Ako se radi o visokom pragu, znači da putanja prolazi područjima s visokim faktorom poželjnosti prolaza. Takva kretanja, koja smatramo sigurnima, možemo izvoditi s većom brzinom. Analogno tome, ako je prag nizak, tada je u putanji kretanja velika mjera nesigurnosti i samim time iznos brzine mora biti manji.

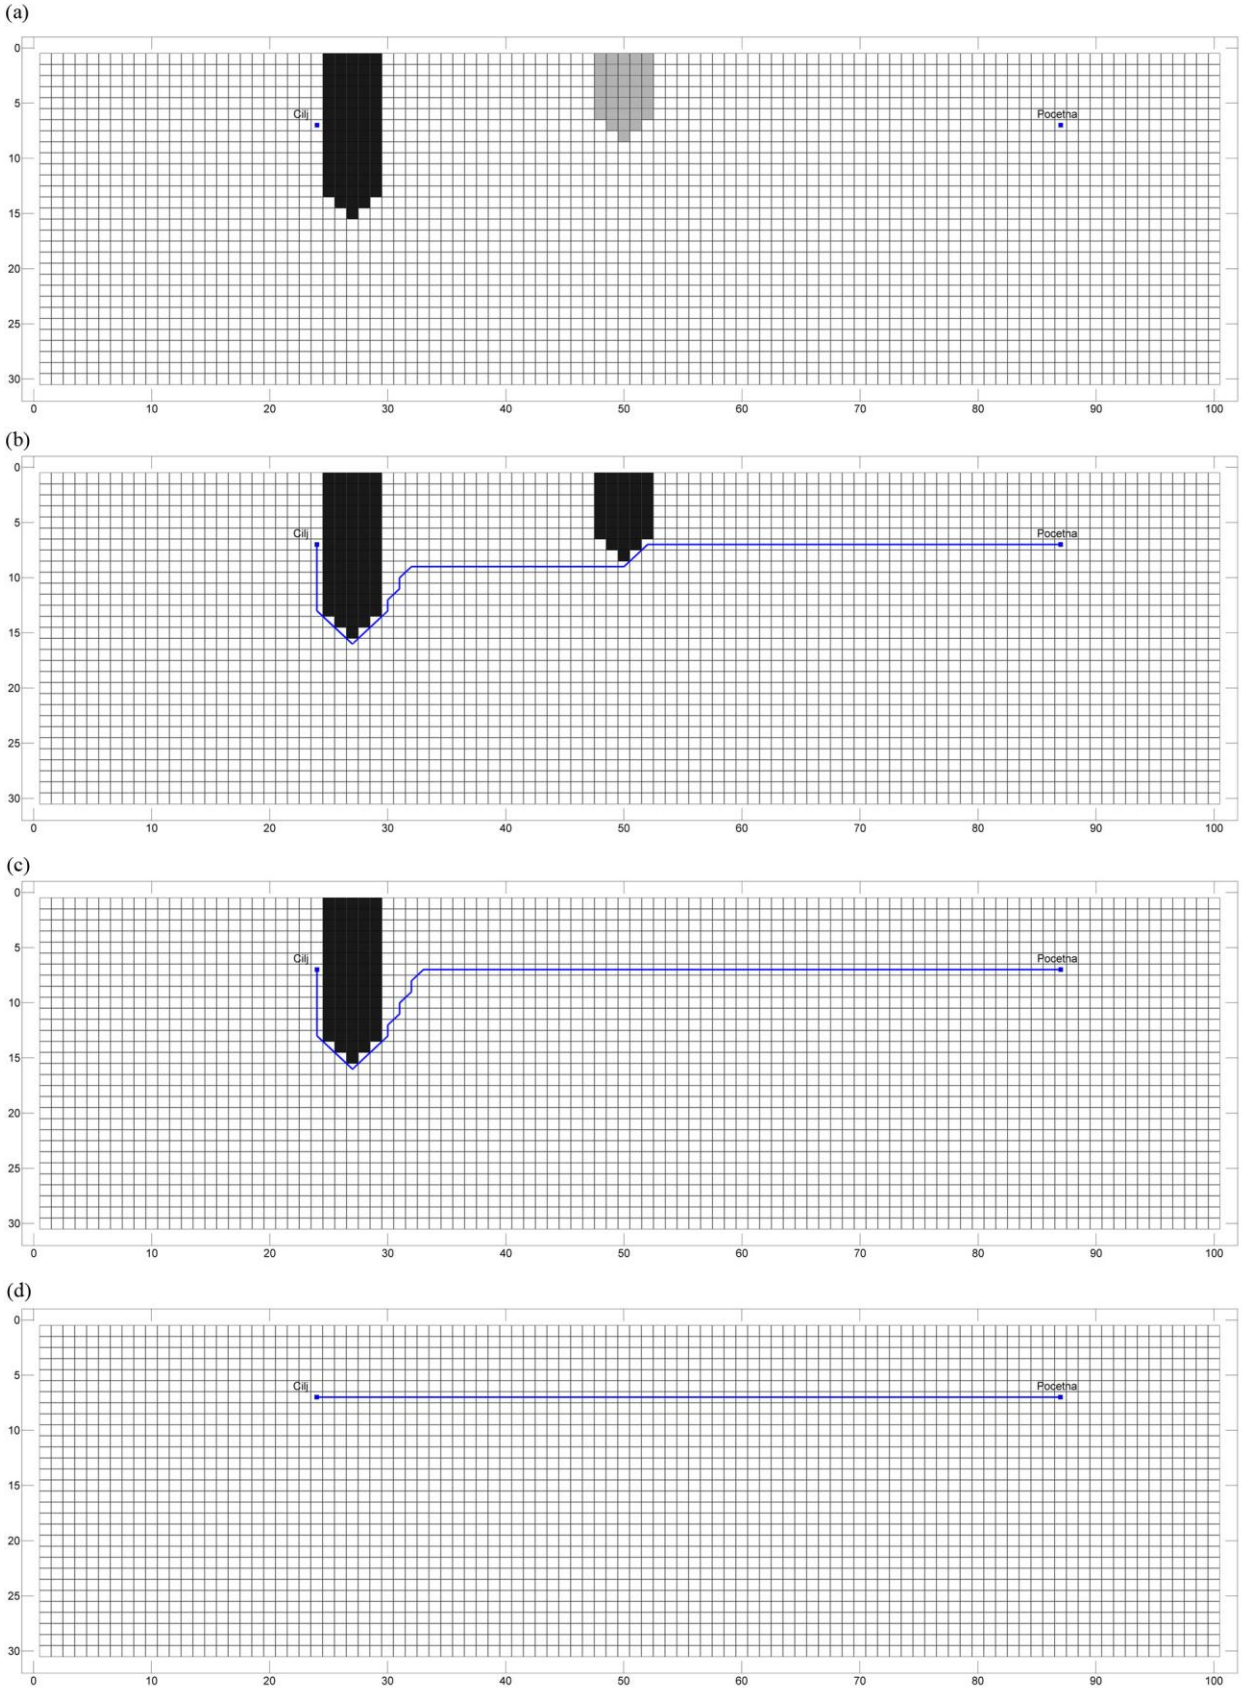

Slika 3.24. *Planirana putanja u konfiguracijskom prostoru – različiti pragovi: a) stvarne vrijednosti, b) planiranje pri visokoj sigurnosti, c) planiranje pri srednjoj sigurnosti, d) planiranje pri vrlo niskoj sigurnosti.*

3.4. Eksperiment

Eksperimentima je potrebno odrediti pragove sila, brzina i ostalih klasifikacijskih elemenata. Provedena su tri eksperimenta kako bi na temelju izmjerenih podataka bilo moguće odrediti potrebne parametre. Prvi eksperiment je proveden sa svrhom definiranja parametara klasifikacije brzine, a drugi radi definiranja parametara klasifikacije pomaka. Trećim eksperimentom određuju se pragovi sila u stacionarom položaju.

Cilj mjerenja je zapisati parametre gesti korisnika, bez utjecaja povratne informacije. Mjerenjem unesenih gesti korisnika te klasifikacijom na temelju toga omogućavaju se realni parametri tj. „prirodniji" pokreti.

3.4.1. Eksperimentalno definiranje parametara klasifikacije brzine

Eksperimentom je potrebno odrediti klasifikacijske parametre kojima je moguće ispravno razaznati kretnju korisnika i svrstati je u jednu od tri skupine:

- brzo
- sporo
- trzaj.

Mjerenje se provodi na temelju triju setova podataka (sporo, brzo, trzaj), svaki s pedeset uzoraka mjerenja. Od korisnika se zahtijeva da izvode različite kretnje koje se opisuju kao različite kategorije:

- kratko brzo
- dugo brzo
- trzaj
- kratko sporo
- dugo sporo.

Svaki je pokret vrlo sadržajan i karakterizira ga niz parametara koji se mijenjaju unutar putanje pokreta. Slične putanje mogu se znatno razlikovati s obzirom na brzinu i primijenjene sile kroz vrijeme kretanja. Primjerice *Slika 3.25* prikazuje usporedbu sličnih putanja od iste početne do iste završne točke s različitim profilom brzine i različitim vremenom izvođenja. Svaka točka naznačena na slici predstavlja uzorak u istom vremenskom intervalu. S obzirom na razmak između točaka može se iščitati profil brzine kroz cijelu putanju.

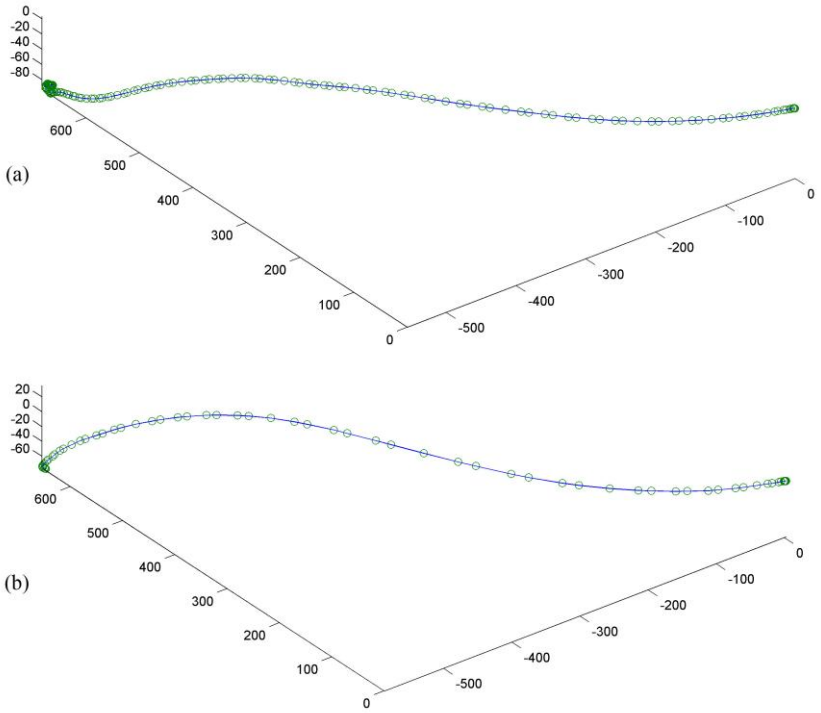

Slika 3.25. *Putanje spore a) i brze b) kretnje.*

Polazna pretpostavka je da je moguće napraviti klasifikaciju pojedinog segmenta na temelju brzine. Tako se klasifikacija oslanja se na apsolutnu brzinu i njezin iznos. Značajke brzine svojstvene za svaki pojedini segment su:

- maksimalna brzina – $\max v$,
- srednja vrijednost brzine – $\bar{v}$.

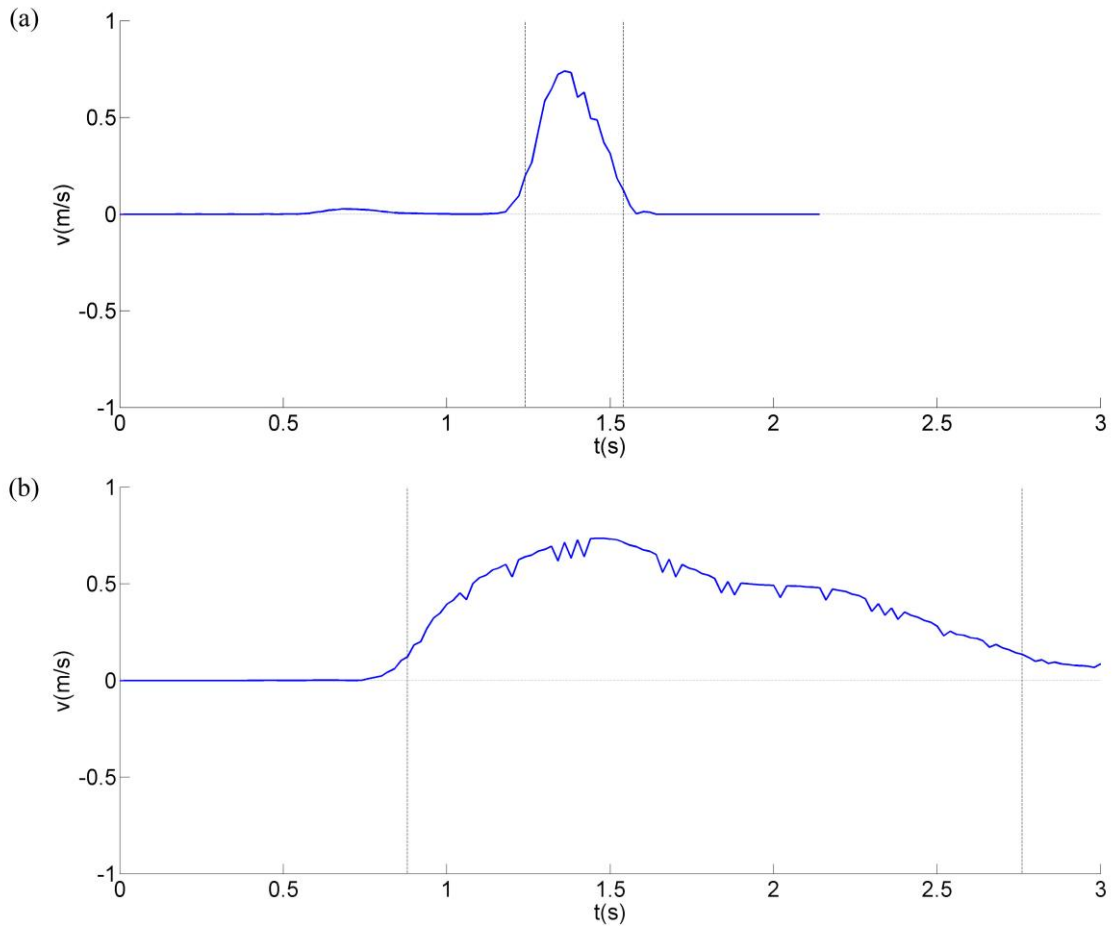

Slika 3.26. *Usporedba brzine kratke brze a) i duge spore b) kretnje*.

Usporedbom numeričkih vrijednosti brzina u intervalu razlučuju se brze kretnje od sporih. No u slučaju različitih dužina putanja javljaju se i različiti profili brzina. Primjerice prilikom izvođenja kratkih pokreta uslijed fizikalnih ograničenja nije moguće ostvariti iste maksimalne brzine kao prilikom dužih pokreta. Zbog toga profili brzine kratkih brzih kretnji dosežu približno jednake vrijednosti maksimalne brzine kao i duge spore kretnje (*Slika 3.26*).

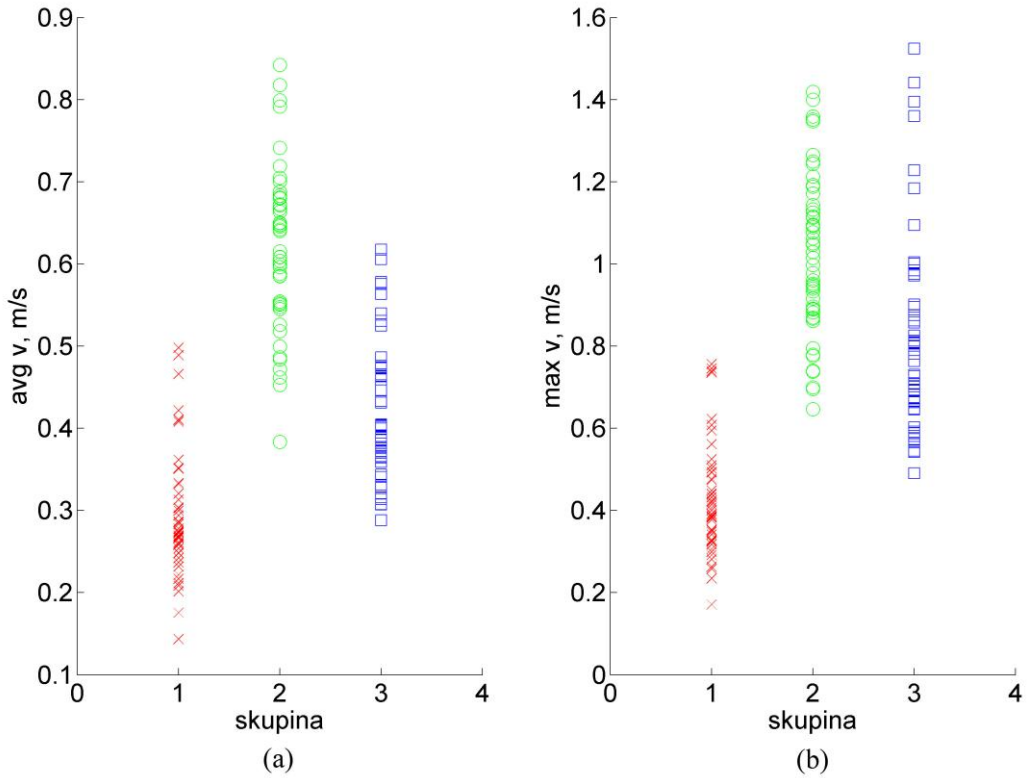

Slika 3.27. *Usporedba raspona a) prosječnih i b) maksimalnih brzina na uzorku.*

Vrijednosti srednjih i maksimalnih brzina kreću se u određenom rasponu s obzirom na vrstu kretnje (*Slika 3.27*). Slika prikazuje podjelu u tri skupine naznačene različitim simbolima (x – sporo, o – brzo, □ – trzaj). Na temelju uzorka donesen je zaključak da nije moguće napraviti pouzdanu klasifikaciju isključivo na parametrima brzine. Zbog toga se uvodi komponenta sile kao klasifikacijski parametar.

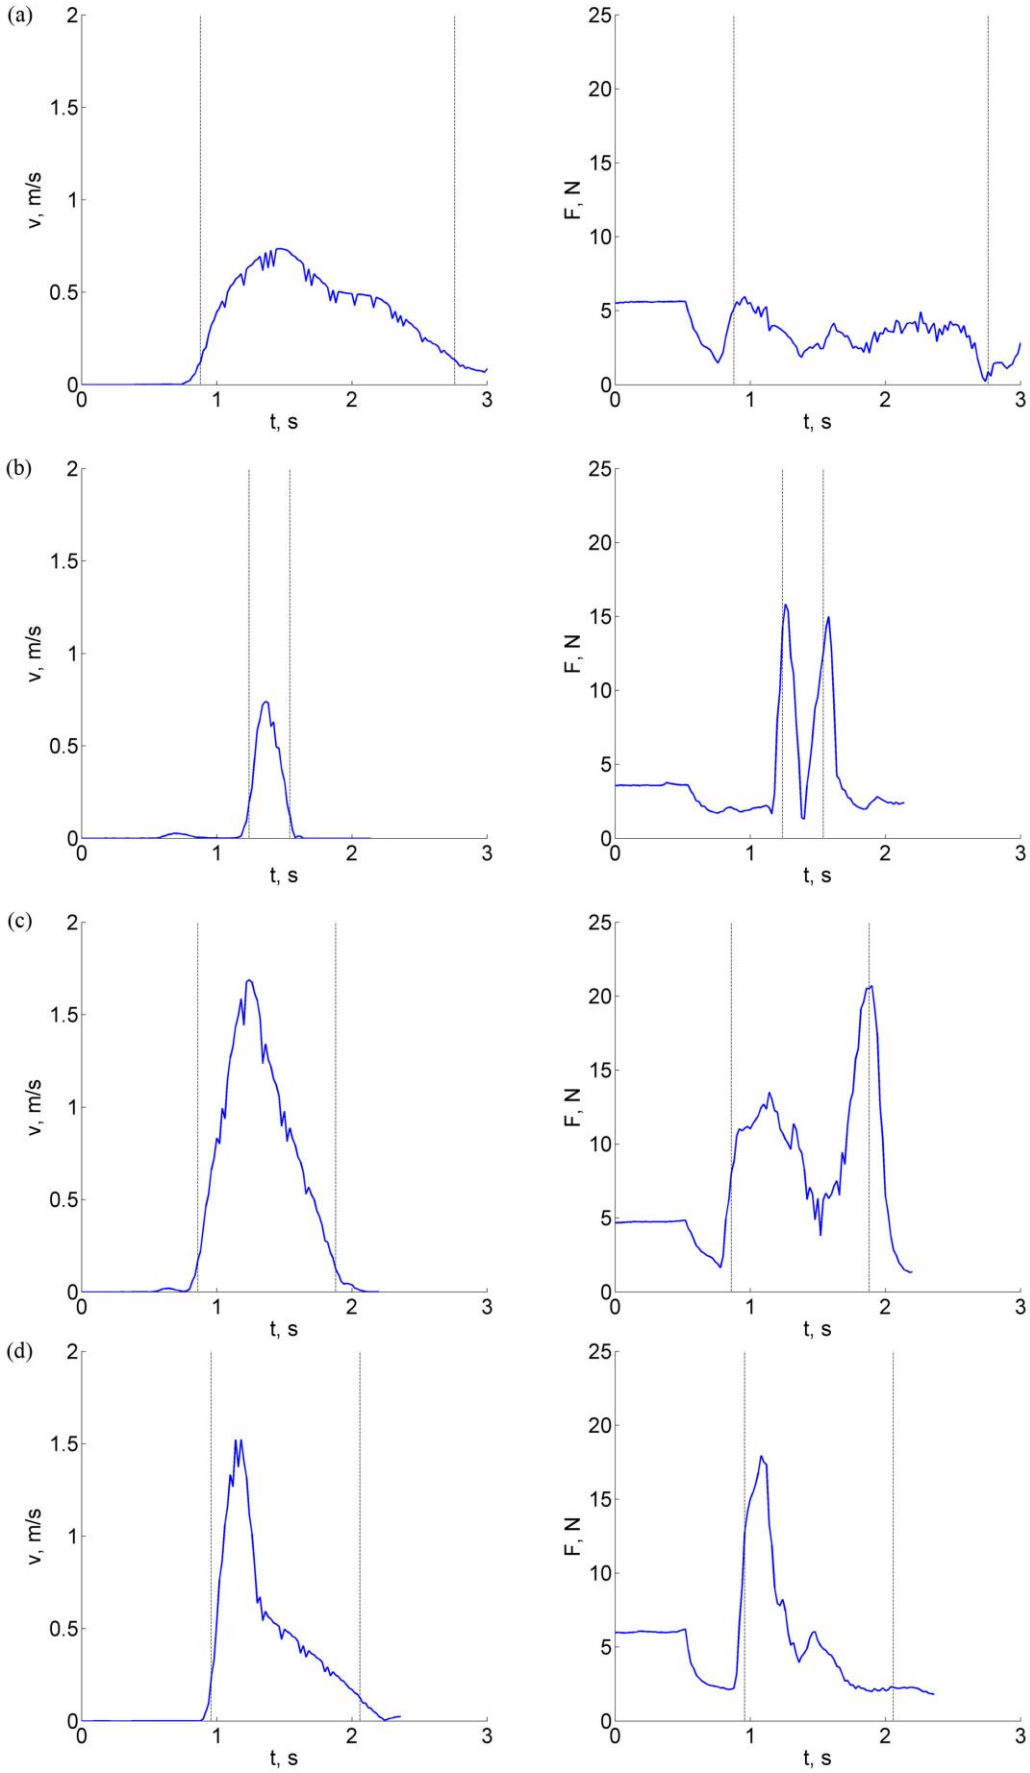

Slika 3.28. *Usporedba brzina i sila a) duge spore, b) kratke brze, c) duge brze kretnje i d) trzaja.*

Kada sagledamo komponentu sile, iz nje je djelomično jasna namjera korisnika. Ako je korisnik primijenio veliku silu, tada se može iščitati namjera da se željena radnja ili kretnja napravi brzo. Na temelju sile, uz faktor brzine, možemo odrediti je li određena kretanja „spora”.

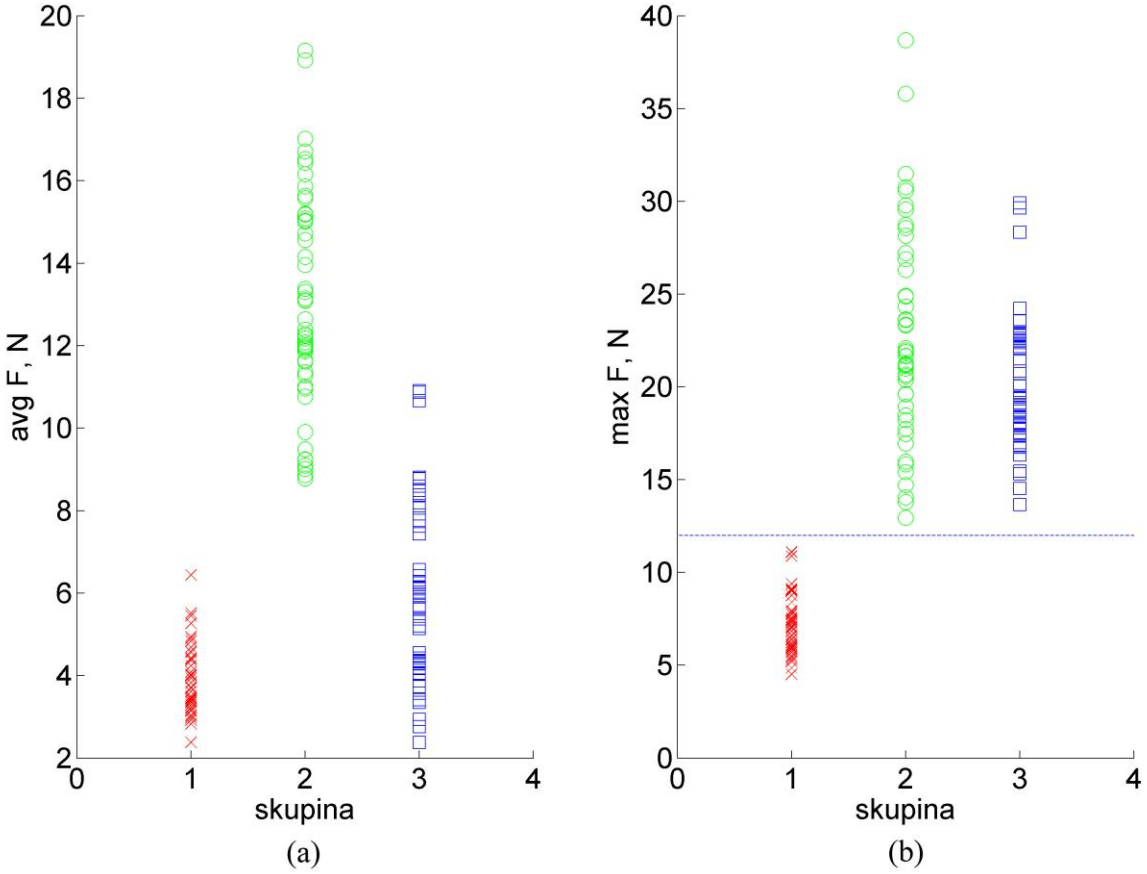

Slika 3.29. Usporedba raspona a) prosječnih i b) maksimalnih sila na uzorku.

Raspon maksimalnih sila omogućava izdvajanje sporih kretnji od brzih kretnji i trzaja na temelju adekvatno postavljenog praga. Na temelju jedne parametarske klasifikacije nije moguće načiniti distinkciju u svim trima skupinama parametara. Zbog toga se prelazi na dvokriterijski model klasifikacije. Pretpostavlja se da je na temelju kombinacije dvaju parametara kojima se obavljaju dvije odvojene distinkcije – avg F, max F – moguće odrediti klasifikacijske parametre. Na temelju četiri parametra (avg v, max v, avg F, max F) moguće je oblikovati šest različitih kombinacija parametara te su oblikovani modeli za svih šest slučajeva.

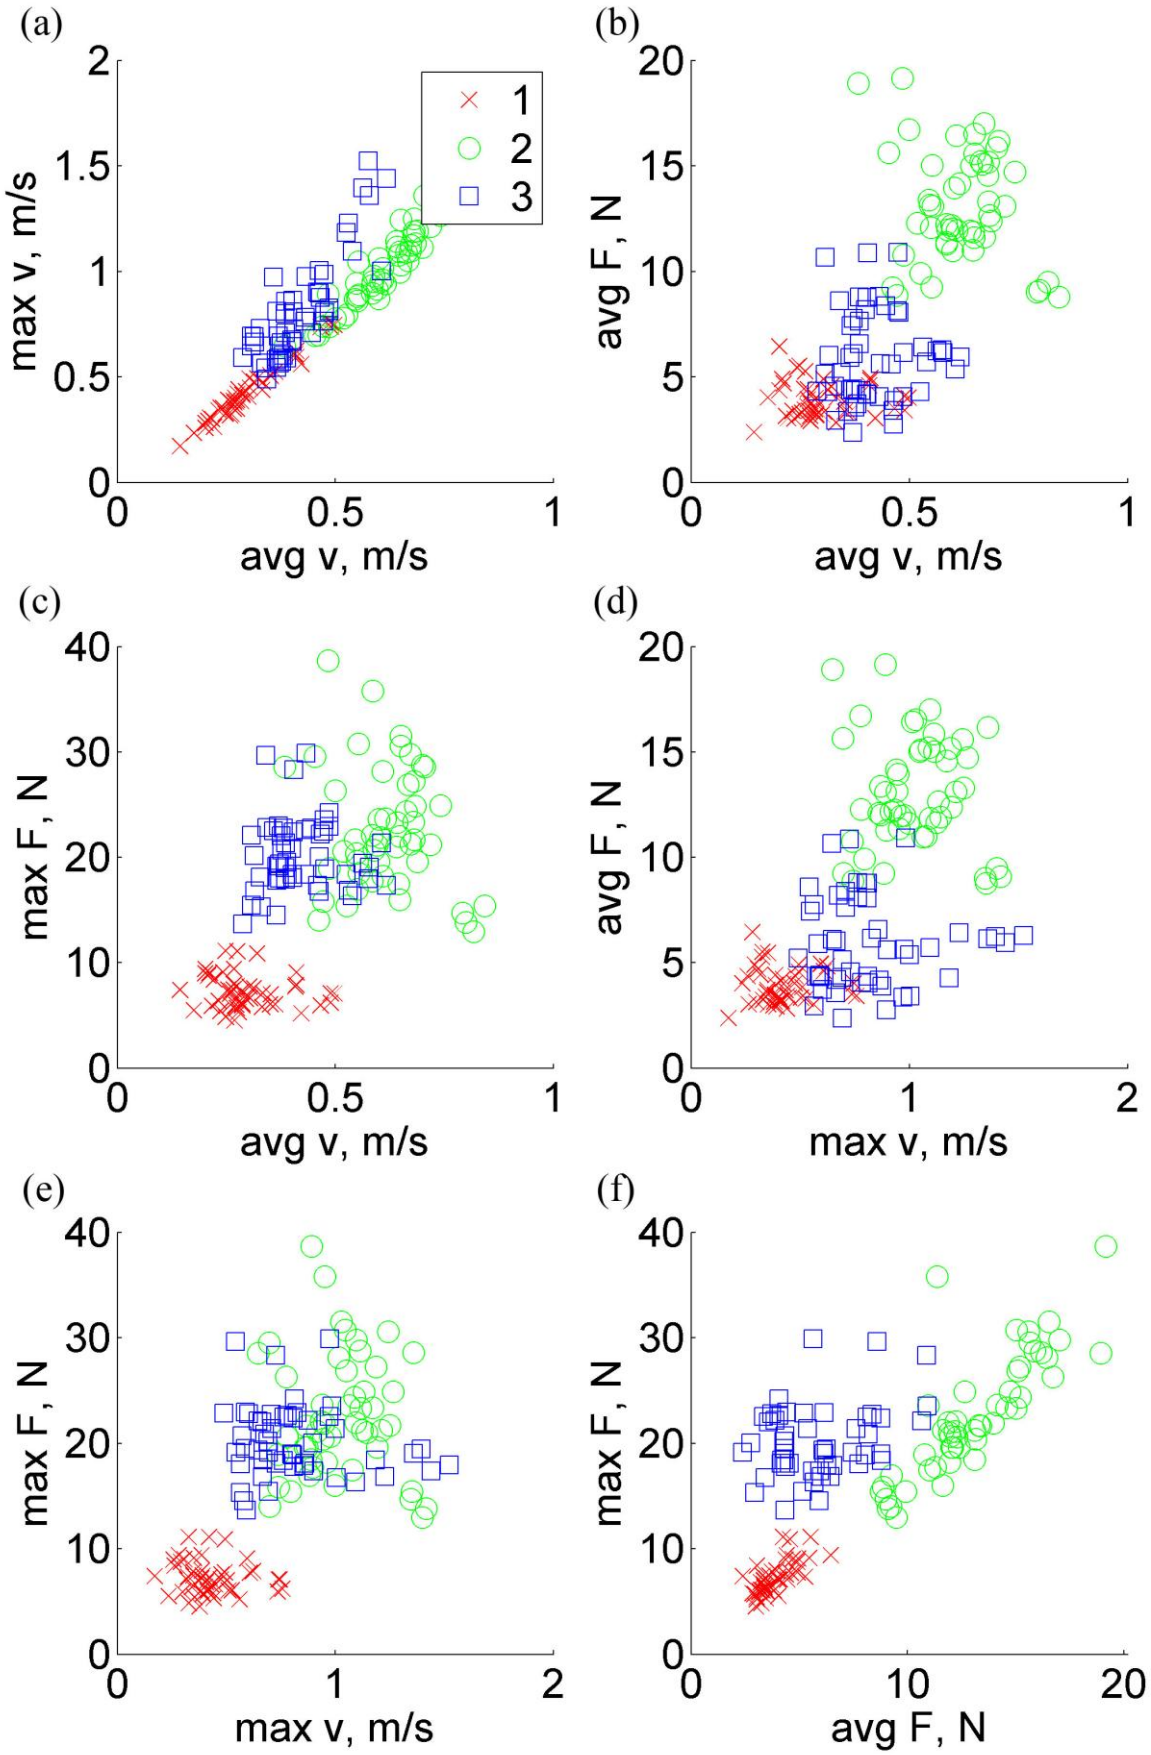

Slika 3.30. *Dvokriterijski modeli klasifikacije.*

Kako je vidljivo iz prikaza (*Slika 3.30*), nijednim modelom nije moguće načiniti isključivu distinkciju parametara. Klasifikacijom koja se temelji na srednjim maksimalnim vrijednostima sila moguće je načiniti najjasniju distinkciju parametara, što potvrđuje pretpostavku odabira dvaju parametara.

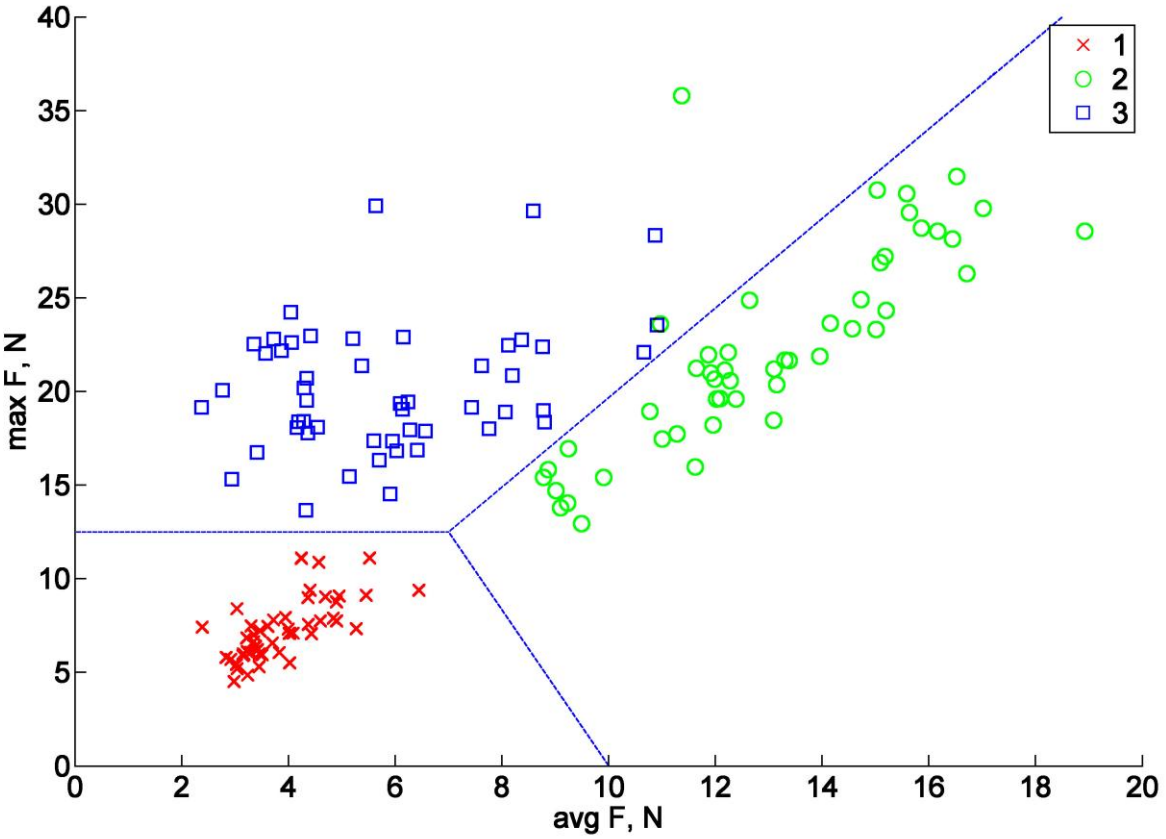

Slika 3.31. *Dvokriterijski model klasifikacije brzine pokreta na temelju prosječnih i maksimalnih sila.*

Dvokriterijski model klasifikacije brzine pokreta na temelju prosječnih i maksimalnih sila je linearno separabilan uz minimalnu pogrešku klasifikacije. Između klasa C_1, C_2, C_3 postavljaju se linearne granice u prostoru značajki koje se mogu izraziti jednadžbom pravca

$$ax + by = c. \tag{3.26}$$

Separacijske jednadžbe mijenjaju se s obzirom na intervale u prostoru. Pripadnost izmjerenog događaja određenoj klasi određuje se na temelju uvjeta pojedinih klasa:

C_1 – spore kretnje

$$y \leq \begin{cases} 12{,}5; \ x \in [0, 7] \\ -4{,}16x + 41{,}66; \ x \in \langle 7, \infty \rangle \end{cases}, \tag{3.27}$$

C_2 – brze kretnje

$$y > -4{,}16x + 41{,}66;\ x \in \langle 7, \infty \rangle$$
$$y \leq 2.39x - 4{,}23;\ x \in \langle 7, \infty \rangle, \tag{3.28}$$

C_3 – trzaj

$$y > \begin{cases} 12{,}5;\ x \in [0, 7] \\ 2.39x - 4{,}23;\ x \in \langle 7, \infty \rangle \end{cases}. \tag{3.29}$$

Radi testiranja uvode se greške prvog i drugog reda. Prilikom testiranja hipoteza (H_0, H_1) binarne klasifikacije greške prvog i drugog reda predstavljaju lažno pozitivne i lažno negativne rezultate testiranja. Greška prvog reda predstavlja vjerojatnost odbacivanja H_0 kada je ona točna, tj. u ovom slučaju vjerojatnost da se mjerenje određene vrste nalazi izvan parametara klasifikacije za tu vrstu. Greška drugog reda manifestira se prihvaćanjem pogrešne H_0 (odbacivanje točne H_1), tj. u ovom slučaju vjerojatnost da je mjerenje druge vrste pogrešno klasificirano kao pozitivno mjerenje ispitivane skupine.

Tablica 3.7. *Dvokriterijska klasifikacija brzine pokreta na temelju prosječnih i maksimalnih sila.*

	Greška	
	I. reda	II. reda
spora kretnja	0%	0%
brza kretnja	4%	0%
trzaj	0%	3,85%

3.4.2. Eksperimentalno definiranje parametara klasifikacije smjera pomaka

Eksperimentom je potrebno odrediti klasifikacijske parametre kojima je moguće ispravno razaznati kretnju korisnika i svrstati je u jednu od tri skupine:

- vertikalno
- horizontalno
- prostorno.

Mjerenje se provodi na temelju triju setova podataka – 20 vertikalnih, 20 horizontalnih i 40 prostornih kretnji. Od korisnika se zahtijeva da rade kretnje različitim brzinama, koje se opisuju kao različite kategorije. Slične putanje mogu se znatno razlikovati s obzirom na brzinu i primijenjene sile tijekom kretanja. Kretnje se razlažu u niz točaka u prostoru kako bi se mogle upotrijebiti za klasifikaciju u trima navedenim skupinama.

Za definiranje konstitutivnog modela potreban je dijagram međusobne ovisnosti odstupanja s obzirom na udaljenost od početne točke. Analiza ovisnosti provedena je na nizovima točaka izmjerenih putanja.

Na slici (*Slika 3.32*) su prikazani svi podaci mjerenja pomaka za sve tri različite vrste pomaka. Različite grupe naznačene su pripadajućim simbolima i bojama: o – vertikalne kretnje, □ – horizontalne kretnje i x – prostorne kretnje. Slika prikazuje određeno odstupanje od osi prilikom vertikalnog pomaka i odstupanje od ravnine kretanja kod horizontalnog pomaka. Može se zapaziti da u većini slučajeva odstupanje raste kako se povećava udaljenost od početne točke.

S obzirom na pravilnosti rasporeda točaka različitih skupina primjenjuje se linearna klasifikacija.

Definirane su tri separacijske jednadžbe pravaca koji dijele prostor u skupine. Pripadnost izmjerenog događaja određenoj klasi određuje se na temelju uvjeta pojedinih klasa:

C_1 – vertikalne kretnje

$$z \geq 3{,}5\sqrt{x^2 + y^2}; \tag{3.30}$$

C_2 – horizontalne kretnje

$$z \leq 0{,}2\sqrt{x^2 + y^2}; \tag{3.31}$$

C_3 – prostorne kretnje

$$z > 0{,}2\sqrt{x^2 + y^2} \ \wedge \ z < 3{,}5\sqrt{x^2 + y^2}. \tag{3.32}$$

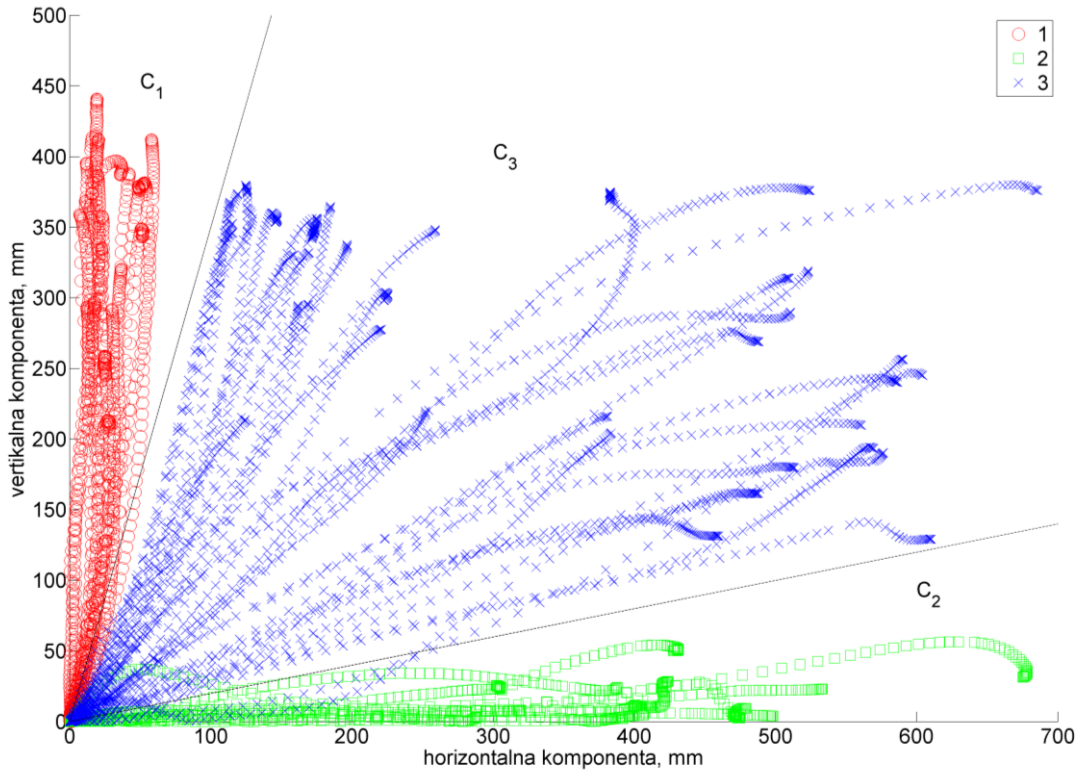

Slika 3.32. *Klasifikacija parametara pomaka – usporedba ovisnosti odstupanja s obzirom na udaljenost.*

3.4.3. Eksperimentalno definiranje parametara klasifikacije sile

S obzirom na greške kinematskog modela uzročno se stvaraju greške prilikom mjerenja vanjskih sila. Pogrešne vrijednosti $\boldsymbol{\tau}_{int}$ utječu na izračun vrijednost momenata $\boldsymbol{\tau}_{ext}$ uslijed vanjskih sila, a time i na vektor sila $\boldsymbol{F}_{ext}$. Eksperimentalnom analizom treba odrediti pragove aktivacije pojedinih obrazaca ponašanja, tj. vrijednosti za klasifikaciju male i velike sile. Provode se mjerenja za tri različite skupine: bez vanjske sile, pri maloj vanjskoj sili i velikoj vanjskoj sili. Vanjsku je silu nametnuo korisnik i bilježi se maksimalni iznos svakog uzorka. Slučaj bez vanjske sile upotrebljava se za određivanje mjernih šumova. Eksperiment je proveden na uzorku od 30 mjerenja za svaku skupinu.

Dijagram (*Slika 3.33*) prikazuje raspone vrijednosti maksimalne sile pojedinog uzorka. Skupina 1 (x) predstavlja šumove prilikom mjerenja sila, skupina 2 (o) predstavlja unos vanjske sile koja se opisuje kao mala sila i skupina 3 (□) predstavlja mjerenje velike vanjske sile.

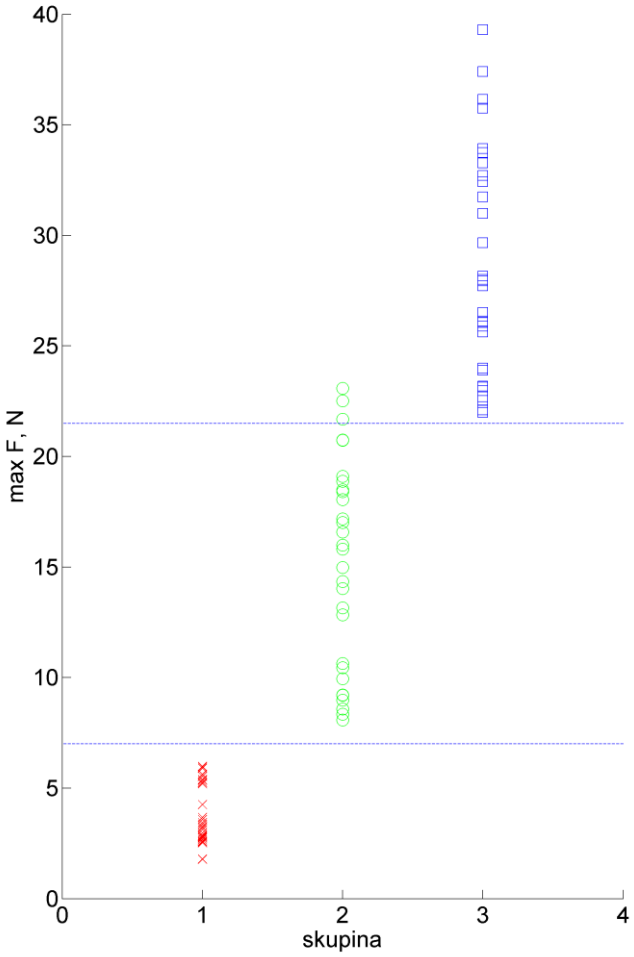

Slika 3.33. *Raspon maksimalnih sila po skupinama uzorka.*

4. Vjerojatnosni model

The theory of probabilities is basically just common sense reduced to calculus; it makes one appreciate with exactness that which accurate minds feel with a sort of instinct, often without being able to account for it.

Laplace

4.1. Teorijska osnova

4.1.1. Vjerojatnost

Pod slučajnim pokusom podrazumijevamo takav pokus čiji ishodi, tj. rezultati nisu jednoznačno određeni uvjetima u kojima izvodimo pokus. Mogućnost ponavljanja danog slučajnog pokusa je proizvoljno konačno mnogo puta. Elementarni događaj

$$\omega_1, \omega_2, \dots \omega_n \tag{4.1}$$

je svaki od konačno mnogo ishoda slučajnog pokusa. Osnovni polazni objekt u teoriji vjerojatnosti jest neprazan skup

$$\Omega = \{\omega_1, \omega_2, \dots \omega_n\}, \tag{4.2}$$

koji zovemo prostorom elementarnih događaja i on reprezentira skup svih ishoda slučajnog pokusa. Cijeli prostor Ω zovemo sigurnim događajem, a prazan skup $\emptyset$ nemogućim događajem.

Familija $\mathcal{F}$ podskupova od Ω je σ-algebra skupova na Ω ako vrijedi:

1. $\Omega \in \mathcal{F}, \emptyset \in \mathcal{F}$, (4.3)
2. $\mathrm{A} \in \mathcal{F} \Rightarrow A^C \in \mathcal{F}$, (4.4)
3. $\mathrm{A}, \mathrm{B} \in \mathcal{F} \Rightarrow \mathrm{A} \cup \mathrm{B} \in \mathcal{F}$. (4.5)

Vjerojatnost je preslikavanje

$$P: \mathcal{F} \to [0,1] \tag{4.6}$$

koje, ako vrijede prethodna svojstva, zajedno s Ω i $\mathcal{F}$ čini vjerojatnosni prostor

$$(\Omega, \mathcal{F}, \mathrm{P}). \tag{4.7}$$

Neka su A i B događaji, $\mathrm{A}, \mathrm{B} \subset \Omega$. Događaj koji se ostvaruje ako se ostvario barem jedan od događaja A, B naziva se unija događaja i označava s $\mathrm{A} \cup \mathrm{B}$. Događaj koji se ostvaruje ako su se ostvarila oba događaja A i B naziva se presjek događaja i označava s $\mathrm{A} \cap \mathrm{B}$. Za događaje A,B skup A\B, koji nazivamo razlika događaja, je događaj koji nastane ako nastane događaj A, a ne nastane događaj B.

Vjerojatnost unije događaja A i B, $\mathrm{A}, \mathrm{B} \subset \Omega$

$$\mathrm{P}(\mathrm{A} \cup \mathrm{B}) = \mathrm{P}(\mathrm{A}) + \mathrm{P}(\mathrm{B}) - \mathrm{P}(\mathrm{A} \cap \mathrm{B}). \tag{4.8}$$

4.1.2. Uvjetna vjerojatnost

Neka su A i B događaji iz vjerojatnosnog prostora $(\Omega, \mathcal{F}, \mathrm{P})$. Računamo vjerojatnost da se dogodio događaj A uz uvjet da nam je poznato da se dogodio događaj B. U tom je slučaju dovoljno samo promotriti elementarne događaje koji čine B i među njima tražiti one povoljne

za događaj A. U tom slučaju tražimo elementarne događaje za presjek $\mathrm{A} \cap \mathrm{B}$ tih događaja. Ova vjerojatnost ovisi o događaju B i naziva se uvjetna vjerojatnost:

$$\mathrm{P}(\mathrm{A}|\mathrm{B}) = \frac{\mathrm{P}(\mathrm{A} \cap \mathrm{B})}{\mathrm{P}(\mathrm{B})}. \tag{4.9}$$

Događaji A i B su nezavisni ako informacija o realizaciji događaja B ne utječe na vjerojatnost događaja A i vrijedi bilo koja od jednakosti: $\mathrm{P}(\mathrm{A}|\mathrm{B}) = \mathrm{P}(\mathrm{A})$ ili $\mathrm{P}(\mathrm{A}|\mathrm{B}) = \mathrm{P}(\mathrm{B})$. Iz toga slijedi:

$$\mathrm{P}(\mathrm{A}|\mathrm{B}) = \mathrm{P}(\mathrm{A}) = \frac{\mathrm{P}(\mathrm{A} \cap \mathrm{B})}{\mathrm{P}(\mathrm{B})}, \tag{4.10}$$

$$\mathrm{P}(\mathrm{A} \cap \mathrm{B}) = \mathrm{P}(\mathrm{A}) \cdot \mathrm{P}(\mathrm{B}). \tag{4.11}$$

4.1.3. Stohastički procesi

Slučajna varijabla na vjerojatnosnom prostoru $(\Omega,\ \mathcal{F}, \mathrm{P})$ je preslikavanje

$$X: \Omega \to \mathbb{R}. \tag{4.12}$$

Slučajna varijabla neovisna je o vremenu. Međutim, mnogi procesi čiji je ishod neizvjestan, a koji se odvijaju u vremenu zahtijevaju da se koncept slučajne varijable poopći tako da uključuje i vremensku komponentu. Neka je $T \subset \mathbb{R}$ skup vremena u kojemu promatramo stohastički proces. Za svako vrijeme $t \in T$ određena je slučajna varijabla koju ćemo označavati s X_t[83].

Uvodimo definiciju:

Stohastički (slučajni) proces je skup slučajnih varijabli

$$X = \{X_t, t \in T\}. \tag{4.13}$$

T je parametarski skup stohastičkog procesa, a $\mathrm{t} \in \mathrm{T}$ je parametar [84].

Stohastički proces možemo shvatiti i kao funkciju dviju varijabli, skupa vremena T i skupa stanja S (skup unutar kojeg proces poprima vrijednosti)

$$X: T \times \Omega \to S. \tag{4.14}$$

Stohastički procesi razlikuju se po prirodi skupa T u dvije grupe: procesi kontinuirani u vremenu i diskretni procesi. Ako je skup T interval, govorimo o kontinuiranom stohastičkom procesu, a u slučaju da je skup T prebrojiv tj. $T = \{t_0,\ t_1,\ t_2, \dots\}$ govorimo o diskretnom stohastičkom procesu. Pritom i slučajne varijable stohastičkog procesa (skup stanja S) mogu biti diskretne ili neprekidne.

Tablica 4.1. *Podjela stohastičkih procesa*.

		Skup T	
		Diskretan	Kontinuiran
Skup S	Diskretan	Markovljevi lanci	Poissonov proces
	Kontinuiran	-	Brownovo gibanje

Teorija Markovljevih lanaca proučava nizove slučajnih varijabli kod kojih je su skup stanja T i skup stanja S diskretni. Poissonov proces (*Slika 4.1* a) primjer je procesa s kontinuiranim vremenom T i diskretnim skupom stanja S. Drugi primjer procesa s kontinuiranim vremenom T, ali s kontinuiranim skupom stanja S je Brownovo gibanje (*Slika 4.1* b). Trajektorija jednodimenzionalnog Brownova gibanja neprekinuta je funkcija.

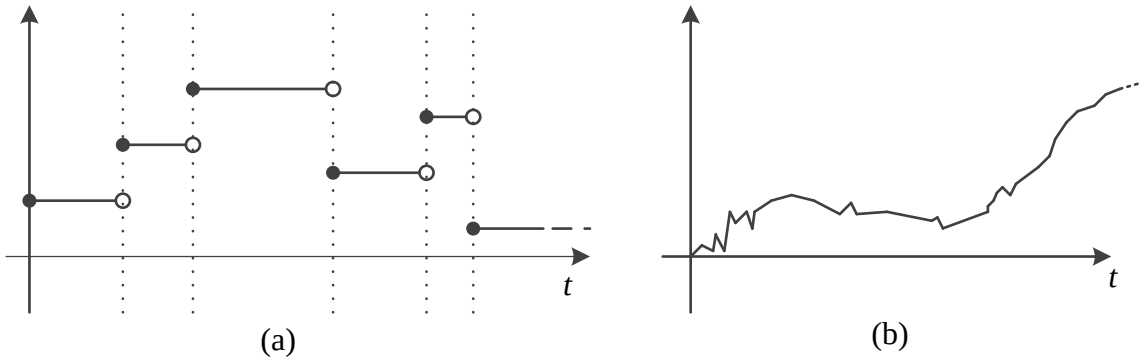

Slika 4.1. *Stohastički procesi: a) Poissonov proces, b) Brownovo gibanje*.

Stohastički procesi mogu se podijeliti na stacionarne i nestacionarne. Stacionarni su oni procesi kod kojih su vjerojatnosne osobine invarijantne u odnosu na pomake vremenskog parametra, dok se kod nestacionarnih procesa te osobine mogu mijenjati.

4.1.4. Markovljevi lanci

Stohastičke procese koji imaju tzv. „svojstvo zaboravljivosti” nazivamo Markovljevim lancima [84]. Markovljev lanac, nazvan po Andreyu Markovu, predstavlja niz stanja sustava. U svakom trenutku sustav može prijeći u neko novo stanje ili može ostati u istom stanju. Promjene stanja nazivaju se tranzicije [85].

Niz diskretnih slučajnih varijabli X_0, X_1, … . zvat ćemo stohastičkim lancem. Slučajne varijable uzimaju vrijednosti u konačnom skupu $S = \{s_0, s_1, \ldots, s_n\}$.

Lanac X_0, X_1, … je Markovljev lanac prvog reda (*Slika 4.2*), ako za sve izbore stanja $s_0, s_1, \ldots, s_n \in S$ vrijedi:

$$P(X_n = s_n | X_{n-1} = s_{n-1}, \ldots, X_0 = s_0) = P(X_n = s_n | X_{n-1} = s_{n-1}) \qquad (4.15)$$

Ovdje trenutak *n* predstavlja sadašnjost, a *0,..., n-1* prošlost. Sadašnje stanje s_n ovisi samo o prethodnom s_{n-1}, ali ne i o načinu na koji je proces dospio u prethodno stanje tj. vrijednostima procesa u ranijim trenutcima.

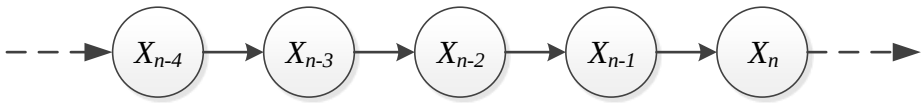

Slika 4.2. *Markovljev lanac prvog reda.*

Markovljev lanac drugog reda (*Slika 4.3*) ovisi o dvama prethodnim stanjima s_{n-1}, s_{n-2} te vrijedi:

$$P(X_n = s_n | X_{n-1} = s_{n-1}, \ldots, X_0 = s_0) = P(X_n = s_n | X_{n-1} = s_{n-1}, X_{n-2} = s_{n-2}) \qquad (4.16)$$

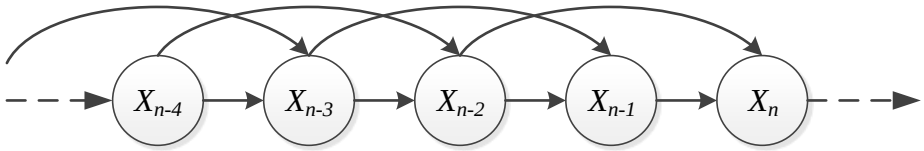

Slika 4.3. *Markovljev lanac drugog reda.*

Sukladno tome, Markovljev lanac *k*-tog reda (*Slika 4.4*) ovisi o *k* prethodnih stanja s_{n-1}, $s_{n-2}, \ldots s_{n-k}$:

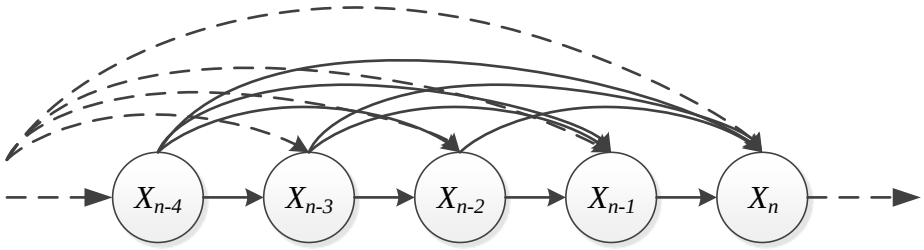

Slika 4.4. *Markovljev lanac k-tog reda.*

Viši redovi lanaca „pamte” dalje u prošlost tj. daju više informacija o procesu. Na primjeru slaganja riječi u rečenici možemo napraviti usporedbu različitih redova Markovljevih lanaca. Na temelju ponuđenih vrijednosti treba odabrati sljedeću riječ u odlomku teksta.

Markovljev lanac prvog reda:

“... ne _____”

- - služi, prolazi, boli, može, znam, radim...

Markovljev lanac drugog reda:

“... glava ne _____”

- - <u>služi</u>, <u>prolazi</u>, <u>boli</u>, <u>može</u>, znam, radim...

Markovljev lanac trećeg reda:

“... viška glava ne _____”

- - služi, prolazi, <u>boli</u>, može, znam, radim...

Markovljev lanac četvrtog reda:

“... od viška glava ne_____”

- - služi, prolazi, <u>boli</u>, može, znam, radim...

Na primjeru se može uočiti kako je mnogo lakše ispravno odabrati sljedeću riječ ako je dostupno više informacija, no ukazuje se i činjenica da se s viškom informacija ne dodaje nova vrijednost, već se samo nepotrebno proširuje model.

4.1.5. Prijelazne vjerojatnosti

Markovljeve lance možemo podijeliti na stacionarne i nestacionarne. Za Markovljeve lance koji imaju svojstvo stacionarnosti prijelazne vjerojatnosti ne ovise o koraku, odnosno trenutku. Veza između slučajnih varijabli X_n i X_{n-1} zadana je prijelaznim vjerojatnostima. Vjerojatnost prijelaza iz stanja s_i u stanje s_j je p_{ij}

$$p_{ij} = P\left(X_n = s_j \middle| X_{n-1} = s_i\right). \tag{4.17}$$

Matrica s elementima p_{ij} označava se s P i naziva se matrica prijelaznih vjerojatnosti.

$$P = (p_{ij})\ i, j \in \{1,2,\ldots,k\}. \tag{4.18}$$

Matrica prijelaznih vjerojatnosti prvog reda za k - broj stanja

$$P = \begin{pmatrix} p_{11} & p_{12} & \cdots & p_{1k} \\ p_{21} & p_{22} & \cdots & p_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ p_{k1} & p_{k2} & \cdots & p_{kk} \end{pmatrix}. \tag{4.19}$$

Elementi ove matrice su nenegativni, $p_{ij} \geq 0$, a zbroj elemenata u svakom njezinom retku jednak je jedan:

$$p_{ij} \geq 0, \quad \sum_{j=1}^{k} p_{ij} = 1 \quad \forall i, j \in \{1,2,\ldots,k\}. \tag{4.20}$$

Primjerice matrica prijelaznih vjerojatnosti P Markovljeva lanca s tri stanja {1, 2, 3} (*Slika 4.5*) glasi

$$\mathrm{P} = \begin{pmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & p_{33} \end{pmatrix}, \tag{4.21}$$

pri čemu je

$$\sum_{j=1}^{3} p_{ij} = 1, i = 1,2,3. \tag{4.22}$$

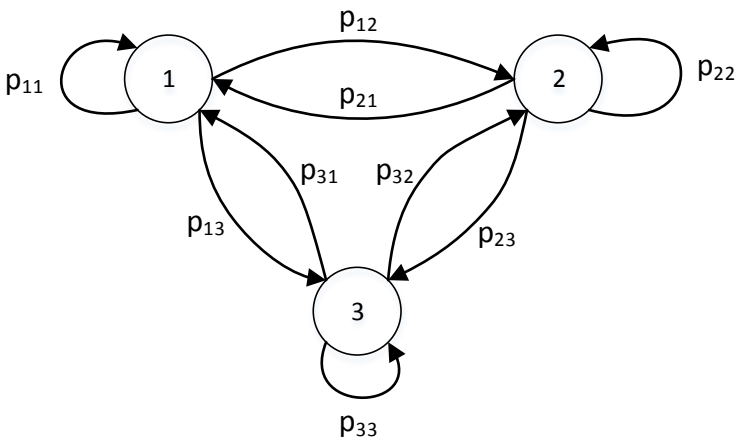

Slika 4.5. *Markovljev lanac s tri stanja.*

U slučaju nestacionarnih lanaca potrebno je definirati matricu prijelaznih vjerojatnosti u *n*-tom koraku

$$P(n) = \left(p_{ij}^{(n)}\right). \tag{4.23}$$

4.2. Model

Model se u interakciji čovjeka s robotom oblikuje kao slijed radnji koje robot obavlja, što u konačnici rezultira robotskim djelovanjem. Potrebno je raščlaniti djelovanje na pojedine elemente djelovanja koji tvore stohastički lanac kroz skup stanja. Vjerojatnosti u stohastičkom lancu moraju se dinamički mijenjati s obzirom na utjecaj fizičke interakcije.

Prema [86] programiranje robota može se podijeliti u nekoliko razina, počevši od najjednostavnijih kretnji pa sve do onih na teoretskoj razini UI – umjetne inteligencije. Crtež prikazuje shemu na četiri razine. Razina tri, ispod UI, naziva se razina zadataka (eng. *tasklevel*). Kao što naziv implicira, programi na toj razini obuhvaćaju cijele zadatke.

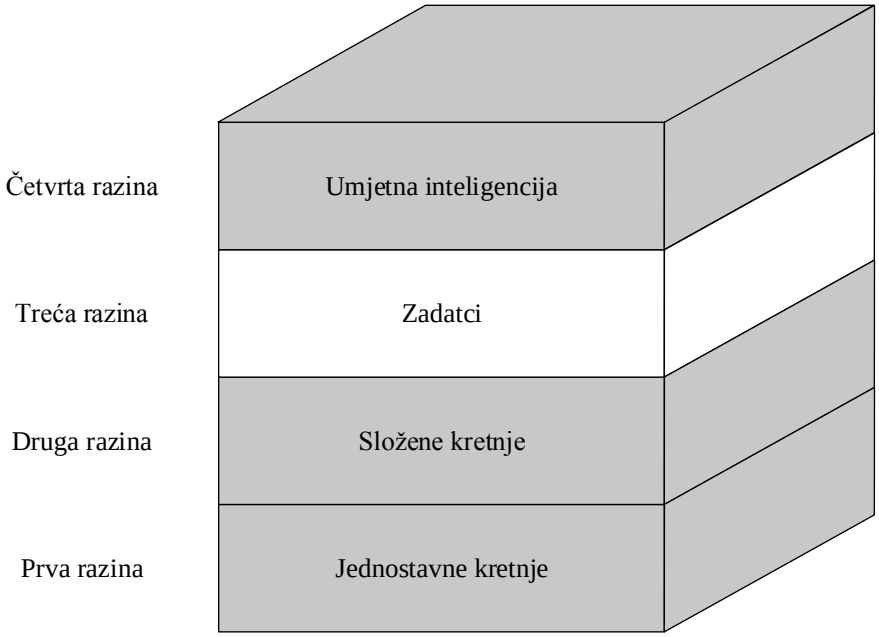

Slika 4.6. *Razine programiranja [86].*

Upravo se na razini zadataka oblikuje stohastički lanac. Elemente djelovanja koji tvore stohastički lanac kroz skup stanja te tako oblikuju model predstavljaju dvije skupine iz višekriterijske definicije prostora – ciljeve i putanje sa svojim prostornim položajem. Ciljevi predstavljaju izvođenje jednostavnih unaprijed definiranih zadataka (izuzimanje, odlaganje, itd.), dok su putanje nizovi prostornih položaja koji povezuju ciljeve. Na temelju takve podjele ciljevi tj. zadatci izdvajaju se kao primarni elementi tj. stanja koja tvore lanac događaja. Stanja sustava dalje se dijele u dvije skupine – prostorno ovisne (zadatci izuzimanja, odlaganja, itd.) i prostorno neovisne (čekanja, početak, kraj, simbolička stanja).

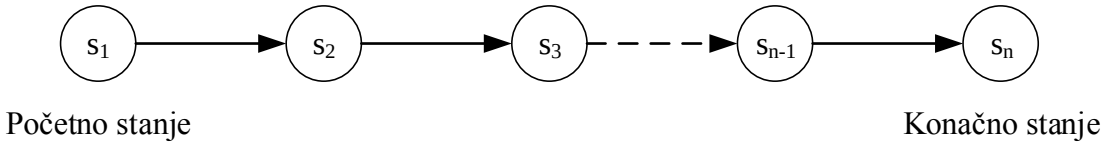

Slika 4.7. *Lanac stanja.*

Tako razložen slijed stanja zapisuje se u obliku Markovljeva lanca. Vjerojatnosti u stohastičkom lancu oblikuju se u skladu sa slijedom izvođenja djelovanja. Prelaskom iz jednog stanja u drugo zapisuju se vrijednosti u prijelaznu matricu

$$P = (p_{ij})\ i, j \in \{1, 2, \ldots, k\}. \tag{4.24}$$

Trenutno stanje sustava opisuje se vektorom

$$x = (x_i)\ i \in \{1, 2, \ldots, k\}. \tag{4.25}$$

Primjerice ako je trenutno stanje početno stanje, vektor x poprima oblik

$$x = (1 \quad 0 \quad \cdots \quad 0). \tag{4.26}$$

U svakom stanju vjerojatnost prelaska u sljedeće stanje dobivamo množenjem trenutnog stanja sustava x_n s prijelaznom matricom P

$$x_{n+1} = x_n P. \tag{4.27}$$

Na temelju najveće vrijednosti

$$s_{n+1} = \max x_{n+1}, \tag{4.28}$$

odabire se prijelaz u sljedeće stanje.

4.2.1. Oblikovanje matrice prijelaznih vrijednosti

Oblikovanje matrice prijelaznih vjerojatnosti objasnit će se na jednostavnom primjeru s nekoliko stanja. U dva slučaja primjera djelovanje se razlikuje utoliko što su sljedovi događaja različiti. Primjerom se želi ispitati i pokazati mogućnost oblikovanja vjerojatnosti za prelazak u naredno stanje ovisno o prethodnim sljedovima elemenata djelovanja.

Prikazani primjer temelji se na Markovljevu lancu prvog reda i sastoji od četiri stanja $s_1,\ s_2,\ s_3,\ s_4 \in S$. Time je prijelazna matrica definirana u obliku

$$\mathrm{P} = \begin{pmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{32} & p_{33} & p_{34} \\ p_{41} & p_{42} & p_{43} & p_{44} \end{pmatrix}. \tag{4.29}$$

Dvije sekvence na temelju kojih će se oblikovati matrice prijelaznih vrijednosti primjera su:

1. $s_1 - s_2 - s_3 - s_4 - s_5$
2. $s_1 - s_4 - s_3 - s_2 - s_1$

Vremenski je definirano da se sekvenca 1 odvila nakon sekvence 2. Time se sekvencama dodjeljuje vremenska komponenta *t*-2 (sekvenca 2) i *t*-1 (sekvenca 1).

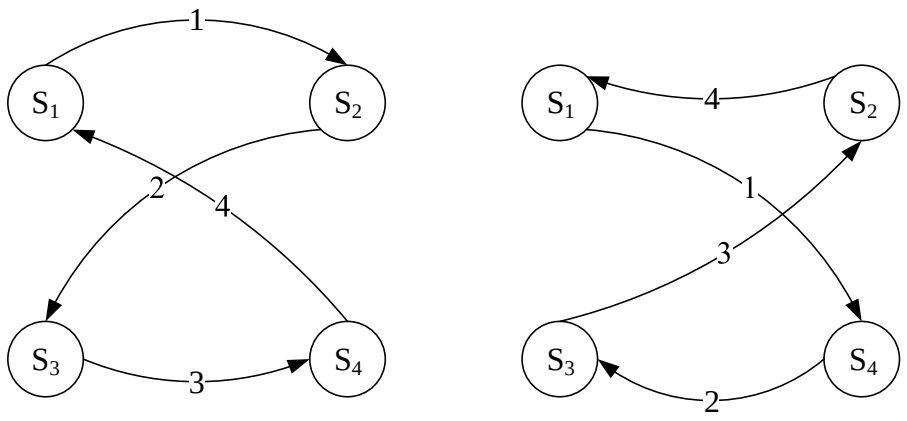

Slika 4.8. *Sekvence* t-*1 i* t-*2*.

Na temelju odabranih sekvenci formiraju se vrijednosti prijelaznih matrica. Vrijednosti elemenata prijelaza oblikuju se prolaskom kroz sekvencu član po član. Primjerice $s_1 - s_2$ tvori prijelaznu vrijednost $p_{12} = 1$. Sve ostale vrijednosti u matrici iznose nula. Time je dan konačni oblik dviju prijelaznih matrica:

$$P_{t-2} = \begin{pmatrix} 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}, \tag{4.30}$$

$$P_{t-1} = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{pmatrix}. \tag{4.31}$$

Oblikovane matrice množe se trenutnim stanjem sustava x_n i u svakom je stanju vjerojatnost prelaska u sljedeće stanje dobivena u obliku vektora x_{n+1}. U slučaju početnog stanja trenutni vektor

$$x_1 = (1 \quad 0 \quad 0 \quad 0), \tag{4.32}$$

množi se s prijelaznom matricom i rezultat je stanje sustava u narednom koraku

$$x_2 = x_1 P_{t-1} = (1 \quad 0 \quad 0 \quad 0) \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{pmatrix} = (0 \quad 1 \quad 0 \quad 0). \tag{4.33}$$

Kako bi se oblikovala konačna matrica prijelaznih stanja koja se temelji na svim prethodnim događajima (sekvencama), sumiraju se sve prijelazne matrice tih događaja

$$P_{sum} = \sum_{i=1}^{n} P_{t-i} \tag{4.34}$$

U slučaju primjera konačna prijelazna matrica dana je vrijednostima

$$P_{sum} = P_{t-1} + P_{t-2} = \begin{pmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \end{pmatrix}. \tag{4.35}$$

Kako bi se izrazila konačna matrica prijelaznih vrijednosti P, potrebno je matricu P_{sum} normirati tako da vrijednost sume elemenata svakog retka iznosi jedan

$$\sum_{j=1}^{k} p_{ij} = 1 \quad \forall i, j \in \{1, 2, \ldots, k\}. \tag{4.36}$$

Normiranjem redaka dobiva se konačni oblik prijelazne matrice

$$P = \begin{pmatrix} 0 & 0{,}5 & 0 & 0{,}5 \\ 0{,}5 & 0 & 0{,}5 & 0 \\ 0 & 0{,}5 & 0 & 0{,}5 \\ 0{,}5 & 0 & 0{,}5 & 0 \end{pmatrix}. \tag{4.37}$$

Na temelju ovakve prijelazne matrice i trenutnog vektora stanja određuje se sljedeće stanje

$$x_2 = x_1 P = (1 \quad 0 \quad 0 \quad 0) \begin{pmatrix} 0 & 0{,}5 & 0 & 0{,}5 \\ 0{,}5 & 0 & 0{,}5 & 0 \\ 0 & 0{,}5 & 0 & 0{,}5 \\ 0{,}5 & 0 & 0{,}5 & 0 \end{pmatrix} = (0 \quad 0{,}5 \quad 0 \quad 0{,}5). \tag{4.38}$$

Na temelju vrijednosti vektora x_2 ne može se odrediti maksimalni element, zbog čega se ne može jednoznačno odrediti naredno stanje. Ovakav slučaj javlja se uslijed različitih prelazaka kroz stanja u svakoj od sekvenci. Razlog tome je, jednostavnim sumiranjem, pridružena jednaka važnost posljednjoj sekvenci i onoj koja joj je prethodila. Pretežno to nije slučaj i u pravilu je najvažnija sekvenca upravo ona koja se odvila posljednja. Zbog toga uvodimo vremensku komponentu i vremensko razlikovanje događaja.

4.2.2. Vremensko razlikovanje

Svrha ljudskog pamćenja je korištenje prošlim događajima za odlučivanje prilikom trenutnog i budućeg djelovanja [87]. Iako se uspješno prisjećanje smatra poželjnom komponentom sustava pamćenja, vrlo je vjerojatno da je i zaboravljanje važna komponenta adaptivnog pamćenja. Rasuđivanje o našim sjećanjima može utjecati na to kako ćemo ih upotrijebiti za oblikovanje naše buduće akcije. Ako smo sigurni u određeno sjećanje za događaj u prošlosti, možemo djelovati odlučno kada nailazimo na sličnu situaciju u budućnosti. Međutim, ako smo manje uvjereni u sjećanje vezano za određeni događaj, nastojat ćemo prikupiti više informacija prije djelovanja [88].

Dugoročno pamćenje blijedi s vremenom, no pohranjeni obrasci čuvaju se dugotrajno [81]. Proces vremenskog razlikovanja oblikuje se upravo tako da replicira dugoročno pamćenje. Protjecanjem vremena i dolaskom novih događaja smanjuje se važnost proteklih iskustava (*Slika 4.9*). Posljednji događaji imaju veću važnost i model ih bolje „pamti" tj. pridaje im veću vjerojatnost. Time se obavljaju s većom sigurnošću i odlučnošću, te nije potrebno dodatno prikupljanje informacija. U slučaju da nije moguće replicirati posljednje sekvence djelovanja, model pruža mogućnost da se „prisjeti" ranijih obrazaca ponašanja i izvede moguću sekvencu djelovanja. Posljedično, takva se sekvenca izvršava s nešto nižom sigurnošću te se time oblikuju i brzine djelovanja.

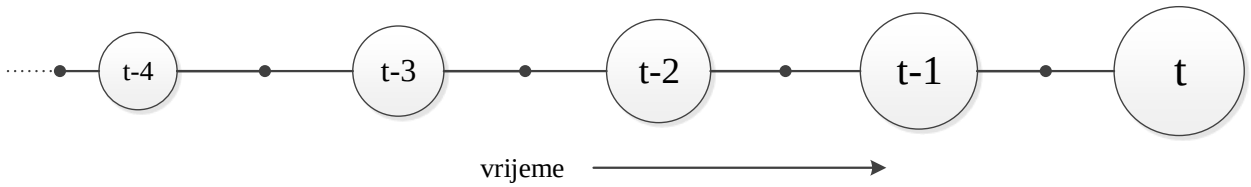

Slika 4.9. *Važnost događaja protjecanjem vremena.*

U skladu s opisanim izmjenama vjerojatnosti potrebno je u model ugraditi komponentu vremenskog razlikovanja. U tom će se pogledu kao uzor sagledati metode učenja podrškom (eng. *reinforcement learning*). Kod učenja podrškom učenje se odvija u interakciji s okolišem. U svakom vremenskom koraku t agent prima informacije o stanju okoliša $s_t \in S$. Na temelju stanja okoline agent odabire svoje djelovanje $a_t \in A(s_t)$, gdje je $A(s_t)$ skup mogućih djelovanja u stanju s_t. Jedan vremenski korak kasnije na temelju posljedica djelovanja agent prima nagradu $r_{t+1} \in R$ [89].

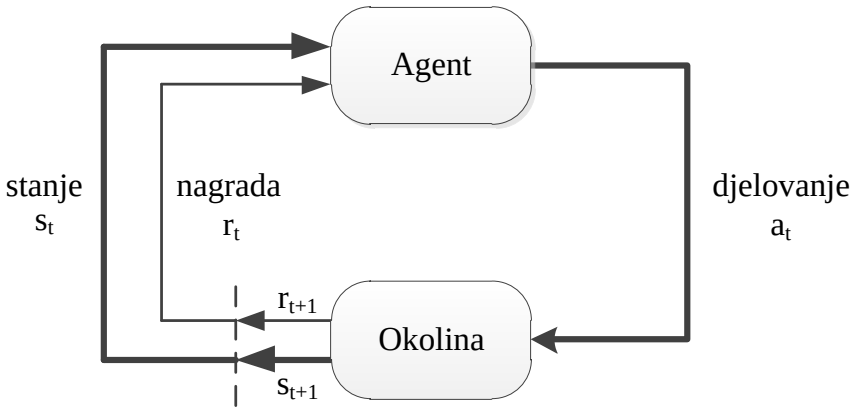

Slika 4.10. *Učenje podrškom [89].*

Poseban slučaj učenja podrškom predstavlja *temporal difference* algoritam. To je primjer algoritama koji uče redukcijom odstupanja između procjena u različitom vremenu [90]. Po uzoru na algoritam oblikuje se vremensko razlikovanje događaja modela.

Vremensko razlikovanje temelji se na eksponencijalnoj funkciji oblika

$$f(t) = \lambda^t, \tag{4.39}$$

gdje baza λ može biti pozitivni realni broj na intervalu $\lambda \in [0,1]$.

Time se vrijednosti koje se pridaju događajima razlikuju kroz vrijeme. Bliži događaji imaju znatno veći faktor utjecaja, a oni udaljeniji u prošlosti mnogo manji. Tako se postupno umanjuje značaj prošlosti – prošle vrijednosti se ionako smatraju pogrešnima.

Upotrebom eksponencijalne funkcije moguće je pamtiti daleko u prošlost, pritom dodjeljujući pripadajuće vrijednosti. Ovisno o bazi eksponenta λ određen je utjecaj prethodnih događaja (*Slika 4.11*). Više vrijednosti, blizu ili na gornjoj granici, daju ravnomjernije vrijednosti i svi događaji, pa tako i oni prošli, imaju ujednačene faktore s malim razlikama. Niske vrijednosti, bliže donjoj granici intervala, daju značajnije razlike faktora.

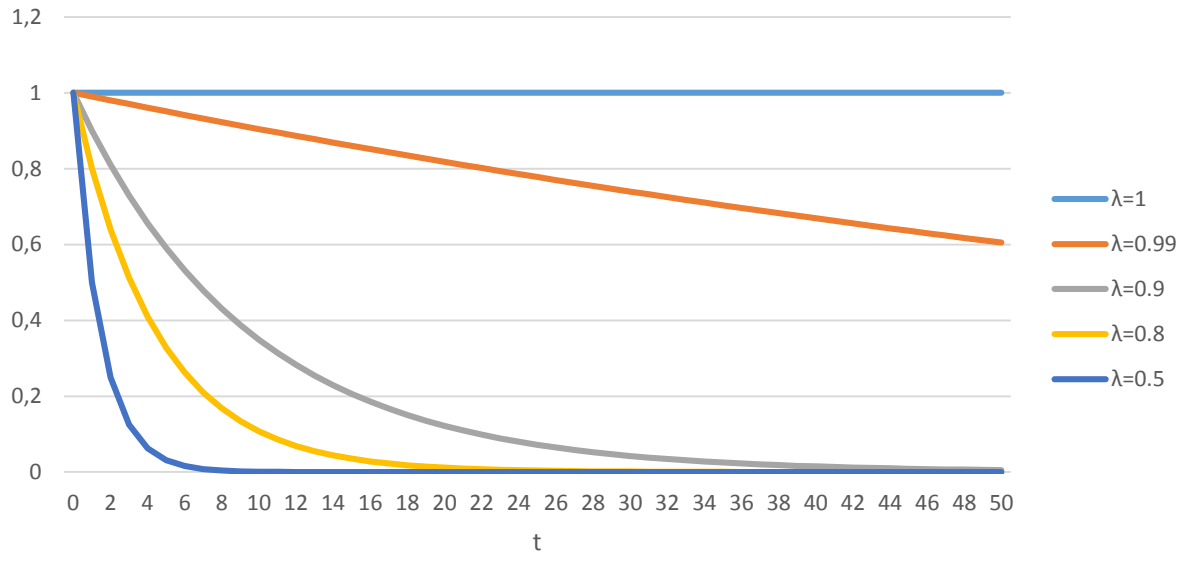

Slika 4.11. *Funkcija vremenskog razlikovanja s obzirom na vrijednost baze λ.*

Kako bi se formirala konačna matrica prijelaznih vrijednosti, potrebno je svakoj prethodnoj matrici dodijeliti određeni faktor s obzirom na to koliko se koraka u prošlost taj slijed događaja odvio. Potom se sumiraju umnošci faktora i prijelaznih matrica

$$P_{sum} = P_{t-1} \times \lambda^0 + P_{t-2} \times \lambda^1 + P_{t-3} \times \lambda^2 + \ldots + P_{t-n} \times \lambda^{n-1}. \tag{4.40}$$

Na temelju zbroja elemenata može se postaviti i opća jednadžba

$$P_{sum} = \sum_{i=1}^{n} P_{t-i} \times \lambda^{i-1}. \tag{4.41}$$

Potom je potrebno je matricu P_{sum} normirati tako da vrijednost sume elemenata svakog retka iznosi jedan

$$P_{sum} \rightarrow P, \sum_{j=1}^{k} p_{ij} = 1, \forall i, j \in \{1, 2, \ldots, k\}. \tag{4.42}$$

4.2.3. Prostorni utjecaj

Predloženi model uzima u obzir prisutnost čovjeka i promjenjivost okoline kao osnovne ulazne parametre. Vjerojatnosti u stohastičkom lancu moraju se dinamički mijenjati s obzirom na utjecaj fizičke interakcije. Na temelju stečenih znanja o slijedu izvršavanja zadanog procesa vremenskim otežavanjem oblikuje se matrica prijelaznih vrijednosti. No uz prethodne sljedove potrebno je uzeti u obzir i trenutno stanje prostora. Postoji mogućnost da određeni cilj nije moguće dosegnuti zbog prepreka koje se trenutno nalaze u prostoru. Zbog toga treba generirati poželjan slijed djelovanja u skladu s ograničenjima. Kako bi model imao određenu autonomiju i mogućnost kretanja prostorom u sklopu višekriterijske interpretacije prostora, obrađen je problem prostornog planiranja. Problem prostornog planiranja vezan je za prostornu mapu i putanje u prostoru. U sklopu višekriterijske interpretacije radnog prostora postoji distinkcija između objekata u okolini, čovjeka, samog robota te putanja robota. U slučaju putanja razlikuju se one naučene od korisnika, putanje generirane pretraživanjem prostora stanja i linearne putanje. S obzirom na prisutnost pripadajućih komponenata višekriterijske interpretacije, segmentima prostora pridjeljuju se vrijednosti, i to u intervalu [0, 1]. Prostornim planiranjem, prvo analizom prethodnih putanja, a potom prema potrebi stvaranjem novih, dodjeljuje se vjerojatnost kojom je moguće ostvariti kretnju od trenutnog stanja do narednog stanja.

Na temelju prostornog planiranja oblikuje se matrica dostupnosti pojedinih stanja ovisno o njihovom prostornom položaju. Matrica dostupnosti

$$D = \left(d_{ij}\right) i, j \in \{1, 2, \ldots, k\}, \tag{4.43}$$

sadrži vjerojatnosti koje opisuju mogućnost prostorne kretnje od stanja *i* do stanja *j*.

Vremenskim otežavanjem oblikovana je

$$P_{sum} = \sum_{i=1}^{n} P_{t-i} \times \lambda^{i-1}, \qquad (4.44)$$

čijim se normiranjem redaka oblikuje konačna prijelazna matrica P.

Na temelju umnožaka pojedinih elemenata konačne prijelazne matrice P i matrice dostupnosti D

$$M = (p_{ij} \times d_{ij})\ i,j \in \{1, 2, \ldots, k\}, \qquad (4.45)$$

oblikuje se konačna matrica modela M na temelju svih navedenih komponenata.

4.3. Eksperiment

Eksperimentom će se ispitati primjenjivost različitih redova Markovljevih lanaca sa svim stanjima i vjerojatnostima prelaska u sljedeće stanje kao elementarnog dijela modela interakcije. Napravit će se usporedbe primjene Markovljevih lanaca prvog reda s procesima višeg reda. Da bi se ispitali razni procesi i kojim se redom Markovljeva lanca mogu opisati načinjen je eksperiment simulacije slučajnih varijabli.

Slučajnim vrijednostima definira se očekivana sekvenca kroz prostor stanja

1 4 3 2 5

na temelju koje se oblikuje prijelazna matrica

$$P = \begin{pmatrix} 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix} \qquad (4.46)$$

Nužan uvjet je da je na temelju prijelazne matrice moguća potpuna ponovljivost inicijalne sekvence. Sekvencu prelaska u sljedeće stanje dobivamo množenjem trenutnog stanja sustava x_n s prijelaznom matricom P

$$x_{n+1} = x_n P. \qquad (4.47)$$

Na temelju najveće vrijednosti

$$s_{n+1} = \max x_{n+1}, \qquad (4.48)$$

odabire se prijelaz u sljedeće stanje. Oblikovani niz stanja čini sekvencu.

Pri različitim slučajnim sekvencama javljaju se i određene sekvence koje nije moguće replicirati prolaskom prijelaznim. Prvi problem koji se javlja je uzastopno ponavljanje elemenata. Na primjeru niza

1 3 4 | 2 | 2 | 5

oblikujemo matricu prijelaznih vrijednosti

$$P = \begin{pmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & 0{,}5 & 0 & 0 & 0{,}5 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix} \tag{4.49}$$

pomoću koje nije moguće jednoznačno replicirati inicijalnu sekvencu. Stanje „2” se s obzirom na prijelazne vrijednosti može odviti samo jednom ili se čak ciklički ponavljati neodređeni broj puta. Tako su neke od mogućih sekvenci koje se mogu generirati:

1 3 4 2 2 5

1 3 4 2 5

1 3 4 2 2 2 5

1 3 4 2 2 2 2 2 5

Povećanjem reda Markovljeva lanca, a time i matrice prijelaznih vrijednosti, djelomično nadilazimo ovaj problem. No isti problem javlja se i kod viših redova u slučaju višestrukog ponavljanja istog elementa.

Drugi problem koji se može pojaviti je ponavljanje dijelova sekvence kroz lanac. Primjerice na sekvenci

1 | 4 | 2 | 4 | 2 | 5

prijelazne su matrice lanaca prvog i drugog reda neprimjenjive, dok se prijelaznom matricom trećeg reda može jednoznačno replicirati inicijalna sekvenca. U slučaju niza

1 | 2 | 4 | 4 | 2 4 2 | 2 | 4 | 4 | 5

prijelazne matrice lanaca prvog, drugog i trećeg reda su neprimjenjive.

Cilj eksperimenta je ispitati u stohastičkim procesima učestalost neprimjenjivosti različitih redova Markovljevih lanaca u procesima s različitim brojem stanja. Također, s obzirom na povećanje složenosti prijelaznih matrica s povećanjem broja stanja i reda Markovljeva lanca treba ispitati vrijeme obrade s obzirom na računsku složenost.

4.3.1. Kompleksnost prijelaznih matrica

S obzirom na red i broj stanja sustava prijelazne matrice P razlikuju se po veličini. Najjednostavnija prijelazna matrica je prvog reda. Varijabla n predstavlja broj stanja sustava. U matrici prvog reda (*Tablica 4.2*) nalazi se n redaka i n stupaca, zbog čega je ukupan broj vrijednosti u matrici $n \times n$.

Tablica 4.2. *Prijelazna matrica prvog reda za pet stanja*.

		t_0				
r.b.	t_{-1}	1	2	3	4	5
1.	1	$p_{1,1}$	$p_{1,2}$	$p_{1,3}$	$p_{1,4}$	$p_{1,5}$
2.	2	$p_{2,1}$	$p_{2,2}$	$p_{2,3}$	$p_{2,4}$	$p_{2,5}$
3.	3	$p_{3,1}$	$p_{3,2}$	$p_{3,3}$	$p_{3,4}$	$p_{3,5}$
4.	4	$p_{4,1}$	$p_{4,2}$	$p_{4,3}$	$p_{4,4}$	$p_{4,5}$
5.	5	$p_{5,1}$	$p_{5,2}$	$p_{5,3}$	$p_{5,4}$	$p_{5,5}$

Kod viših redova Markovljeva lanca prijelazne matrice su nešto većih dimenzija. Primjerice prijelazna matrica trećeg reda (*Tablica 4.3*) sastoji se od znatno više redaka jer mora sadržavati sve varijacije elementa t_{-3}, t_{-2} i t_{-1}. Neovisno o redu Markovljeva lanca, broj stupaca je jednak broju stanja *n*.

Tablica 4.3. *Prijelazna matrica trećeg reda za pet stanja.*

				t_0				
r.b.	t_{-3}	t_{-2}	t_{-1}	1	2	3	4	5
1.	1	1	1	$p_{1,1}$	$p_{1,2}$	$p_{1,3}$	$p_{1,4}$	$p_{1,5}$
2.	1	1	2	$p_{2,1}$	$p_{2,2}$	$p_{2,3}$	$p_{2,4}$	$p_{2,5}$
3.	1	1	3	$p_{3,1}$	$p_{3,2}$	$p_{3,3}$	$p_{3,4}$	$p_{3,5}$
4.	1	1	4	$p_{4,1}$	$p_{4,2}$	$p_{4,3}$	$p_{4,4}$	$p_{4,5}$
5.	1	2	5	$p_{5,1}$	$p_{5,2}$	$p_{5,3}$	$p_{5,4}$	$p_{5,5}$
6.	1	2	1	$p_{6,1}$	$p_{6,2}$	$p_{6,3}$	$p_{6,4}$	$p_{6,5}$
7.	1	2	2	$p_{7,1}$	$p_{7,2}$	$p_{7,3}$	$p_{7,4}$	$p_{7,5}$
…								
124.	5	5	4	$p_{124,1}$	$p_{124,2}$	$p_{124,3}$	$p_{124,4}$	$p_{124,5}$
125.	5	5	5	$p_{125,1}$	$p_{125,2}$	$p_{125,3}$	$p_{125,4}$	$p_{125,5}$

S obzirom na red procesa i broj stanja, matrica se sastoji od n^{red} varijacija tj. redaka i n stupaca, zbog čega je ukupan broj vrijednosti u matrici $n^{red} \times n$ (*Tablica 4.4*).

Tablica 4.4. *Ukupan broj vrijednosti prijelazne matrice s obzirom na red procesa i broj stanja.*

	Ukupno vrijednosti u matrici			
Broj stanja	1. red	2. red	3. red	4. red
5	25	125	625	3125
10	100	1000	10000	100000
15	225	3375	50625	759375
30	900	27000	810000	24300000
40	1600	64000	2560000	1.02E+08
50	2500	125000	6250000	3.13E+08

4.3.2. Slučajne vrijednosti

Generatorom slučajnih brojeva tvori se niz koji se sastoji od elemenata skupa $S = \{s_0,\ s_1, \ldots, s_n\}$ mogućih stanja lanca. Skup S je konačan ili prebrojiv skup bez gomilišta. Niz mora biti diskretno uniforman – svaka slučajna varijabla mora biti jednako zastupljena.

Kako bi se mogli verificirati rezultati eksperimenta, potrebno je načiniti provjeru razdiobe slučajnih vrijednosti. To će se prikazati na dva slučaja s različitim brojem stanja – deset i trideset stanja.

Za skup S koji sadrži deset stanja vrijedi sljedeće:

prostor događaja

$$\Omega = \{1,2,3,4,5,6,7,8,9,10\}, \tag{4.50}$$

vrijednosti slučajne varijable

$$X(\Omega) = \{2,3,4,5,6,7,8,9,10\}, \tag{4.51}$$

i funkcija gustoće vjerojatnosti

$$f(x) = \begin{Bmatrix} \frac{1}{9}, x \in \{2,3,4, \ldots 10\} \\ 0 \qquad \text{ostalo} \end{Bmatrix}. \tag{4.52}$$

Tablica relativnih frekvencija (*Tablica 4.5*) prikazuje distribuciju vrijednosti slučajne varijable na uzorku veličine N = 1 000 000 slučajnih vrijednosti.

Tablica 4.5. *Relativne frekvencije za 10 stanja.*

x	2	3	4	5	6
$f(x)$	0.11077	0.11081	0.11105	0.11123	0.11132
x	7	8	9	10	
$f(x)$	0.11147	0.11099	0.11088	0.11148	

Statističku značajnost iskazujemo pomoću P-vrijednosti, koja se osniva na teorijskoj distribuciji. P-vrijednost je u ovom slučaju visokog iznosa (0,716) i na temelju nje ne odbacujemo inicijalnu hipotezu da vrijednosti slučajne varijable za deset stanja pripadaju diskretno uniformnoj distribuciji.

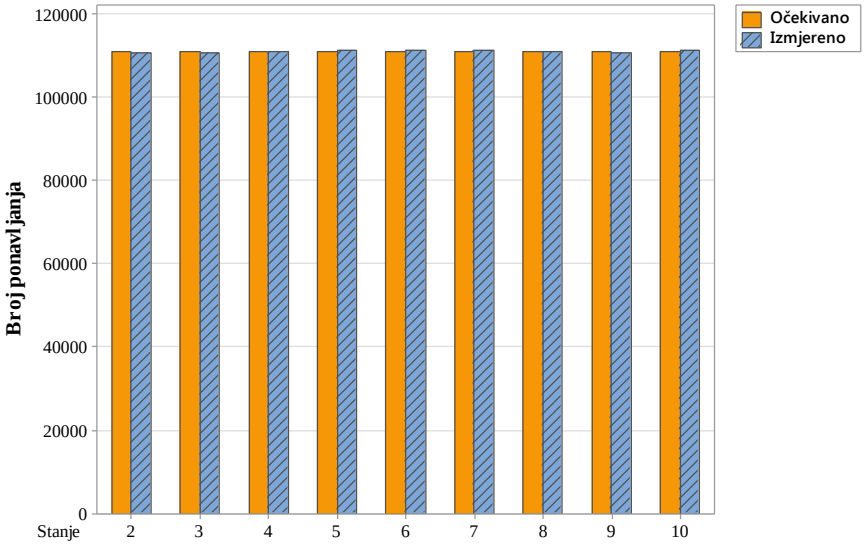

Slika 4.12. *Distribucija slučajnih varijabli za deset stanja*.

Za skup S koji sadrži trideset stanja vrijedi sljedeće:

prostor događaja

$$\Omega = \{1, 2, 3, 4, 5, 6, \dots 30\}, \tag{4.53}$$

vrijednosti slučajne varijable

$$X(\Omega) = \{2, 3, 4, 5, 6, \dots 30\}, \tag{4.54}$$

i funkcija gustoće vjerojatnosti

$$f(x) = \begin{Bmatrix} \frac{1}{29}, x \in \{2, 3, 4, \dots 30\} \\ 0 \qquad ostalo \end{Bmatrix}. \tag{4.55}$$

Tablica relativnih frekvencija (*Tablica 4.6*) prikazuje distribuciju vrijednosti slučajne varijable na uzorku veličine N = 1 000 000 slučajnih vrijednosti.

Tablica 4.6. *Relativne frekvencije za 30 stanja.*

x	2	3	4	5	6	7	8	9
$f(x)$	0.03451	0.03438	0.03446	0.03455	0.03474	0.03451	0.03426	0.03448
x	10	11	12	13	14	15	16	17
$f(x)$	0.03448	0.03491	0.03437	0.03471	0.03453	0.03425	0.03443	0.03477
x	18	19	20	21	22	23	24	25
$f(x)$	0.03463	0.03417	0.03444	0.03433	0.03437	0.03464	0.03439	0.03444
x	26	27	28	29	30			
$f(x)$	0.03443	0.03441	0.03439	0.03469	0.03435			

P-vrijednost je i u ovom slučaju visokog iznosa (0,742) i na temelju nje ne odbacujemo inicijalnu hipotezu da vrijednosti slučajne varijable za trideset stanja pripadaju diskretno uniformnoj distribuciji.

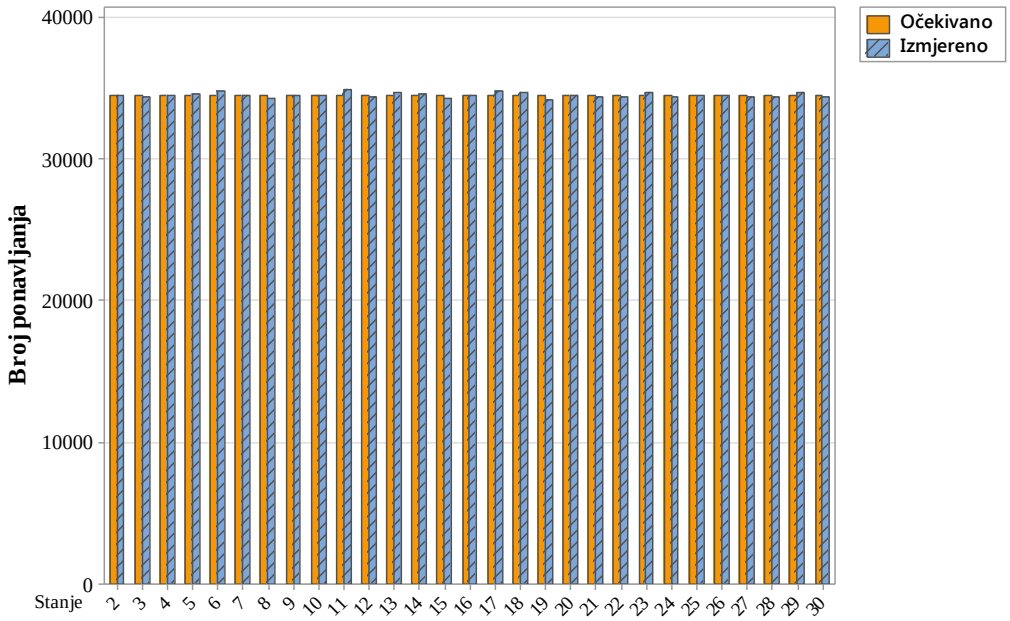

Slika 4.13. *Distribucija slučajnih varijabli za trideset stanja.*

Na temelju relativnih frekvencija i p-vrijednosti u oba ispitana slučaja možemo zaključiti da vrijednosti pripadaju diskretnoj uniformnoj distribuciji.

Generirani niz se potom dijeli u manje nizove, kada je vrijednost u početnom nizu jednaka vrijednosti konačnog stanja. Postavljanjem pravila svaki se niz sastoji od barem tri stanja – početnog stanja (1), slučajnih elemenata niza te konačnog stanja s_n (n – broj stanja). Ovako definiranim razlaganjem razdiobu dužine nizova trebala bi opisivati geometrijska distribucija.

Geometrijska distribucija je vezana za neovisno ponavljanje istog pokusa s ishodima „uspjeh” i „neuspjeh”. Međutim, ona se ne primjenjuje za opisivanje broja uspjeha, već za opisivanje broja ponavljanja pokusa do prvog uspjeha [91]. U ovom slučaju „uspjeh” predstavlja dolazak u konačno stanje s_n, zbog čega se lanac prekida, a „neuspjeh” bilo koje drugo stanje, zbog čega se niz nastavlja. Preciznije govoreći, neka je $p = 1/n$ vjerojatnost pojavljivanja konačnog stanja s_n u svakom od nezavisnih ponavljanja istog pokusa $p \in \langle 0,1 \rangle$. Geometrijskom distribucijom opisana je slučajna varijabla koja daje broj potrebnih pokusa, tj. dužinu niza, da bi se realizirao taj događaj.

Slučajna dužina niza k ima geometrijsku distribuciju s vjerojatnostima

$$p_k = p(1-p)^{k-1}. \tag{4.56}$$

Na temelju slučajnih vrijednosti i veličine uzorka N = 100 000 slučajnih nizova aritmetička sredina dužine lanca za deset stanja iznosi 10,98. Sličnim pokusom, također na uzorku od N = 100 000 slučajnih nizova, utvrđena je aritmetička sredina dužine lanca za trideset stanja koja iznosi 31,13.

Tablica 4.7. *Razdioba dužine nizova.*

Broj stanja	Aritmetička sredina	Standardna devijacija	Minimum	Medijan	Maksimum
10	10.98	8.43	3	8.00	102
30	31.13	28.67	3	22.00	379

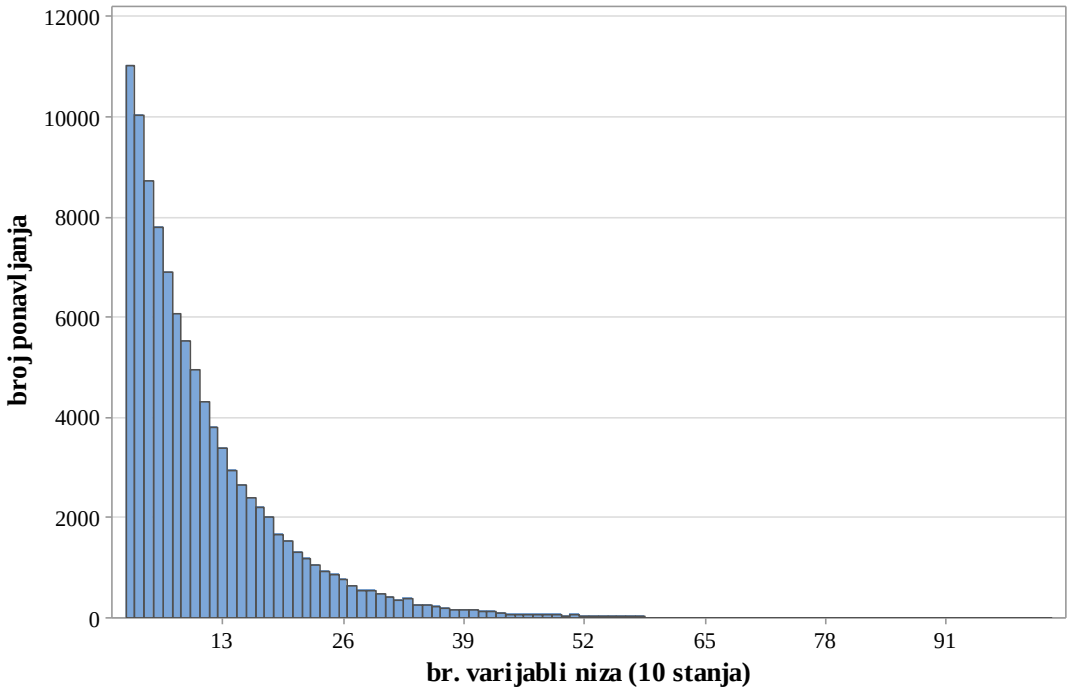

Slika 4.14. *Razdioba dužine lanaca za deset stanja.*

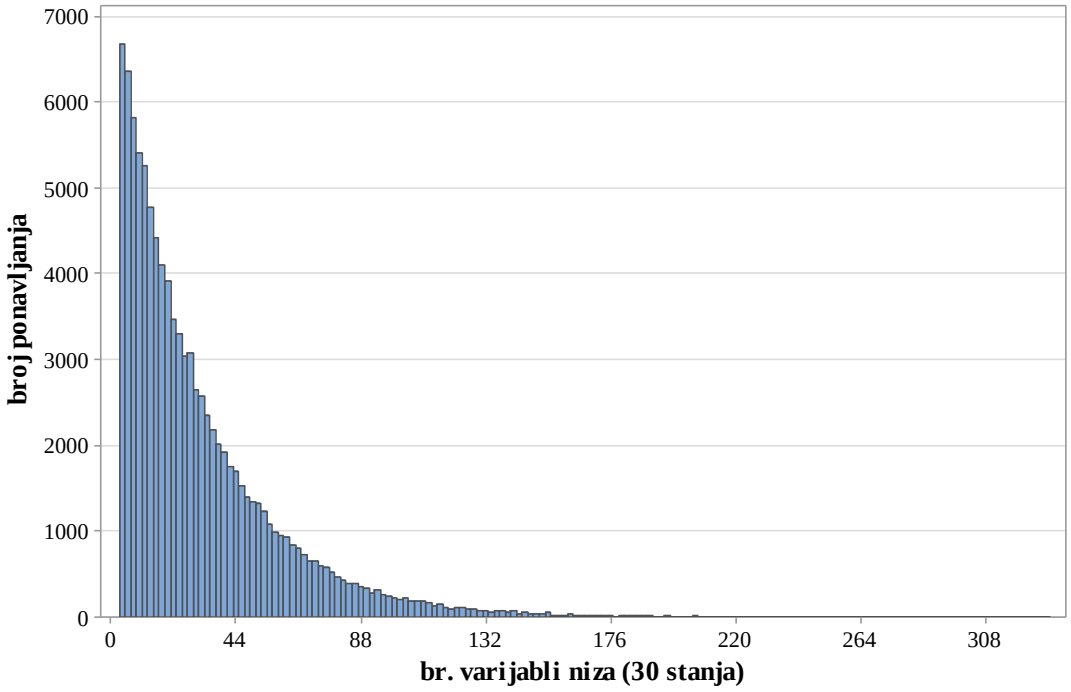

Slika 4.15. *Razdioba dužine lanaca za trideset stanja.*

4.3.3. Broj uzastopnih ponavljanja u slučajnim lancima

Nakon verifikacije da generirane slučajne vrijednosti pripadaju odgovarajućim distribucijama potrebno je provesti ciljane eksperimente. Prvo će se ispitati broj uzastopnih ponavljanja istog stanja. Kako se u slučajnim pokusima određena stanja mogu uzastopno ponavljati, potrebno je ispitati učestalost ponavljanja u ovisnosti s brojem ponavljanja. Eksperimentom je izmjerena vjerojatnost uzastopnog ponavljanja 0, 1, 2, 3, > 4 puta u lancima s 5, 10, ... , 50 stanja. Broj lanaca (uzoraka) za svaki broj stanja iznosi 10 000.

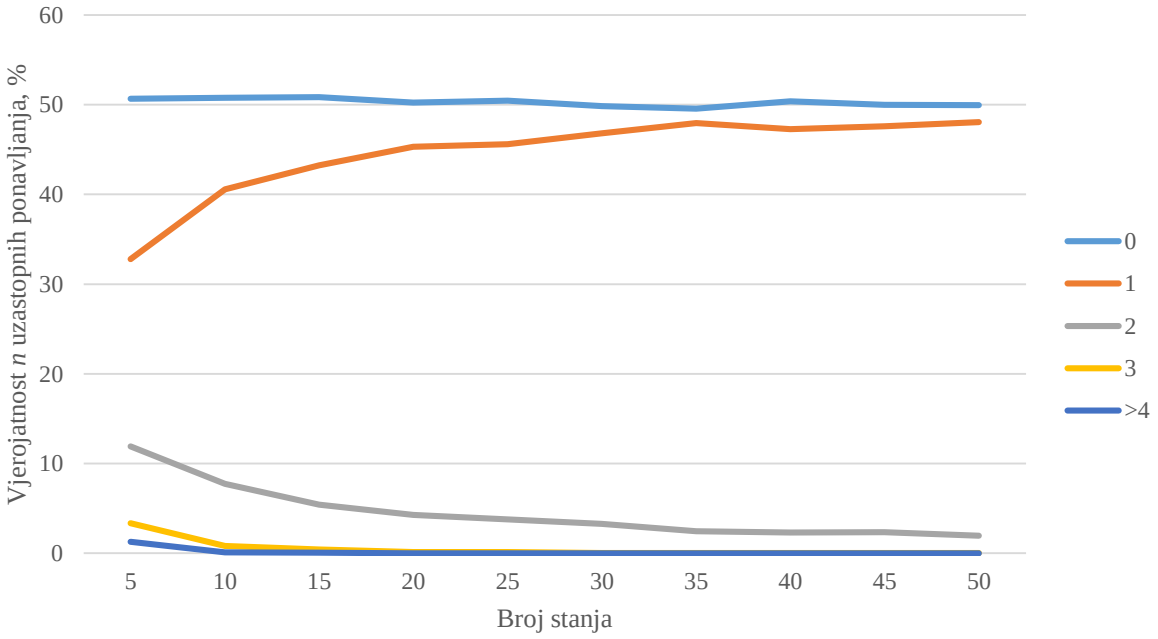

Slika 4.16. *Vjerojatnost događaja uzastopnih ponavljanja.*

Tablica 4.8. *Vjerojatnost događaja uzastopnih ponavljanja.*

Broj stanja	Vjerojatnost *n* uzastopnih ponavljanja, %				
	0	1	2	3	>4
5	50.68	32.8	11.91	3.34	1.27
10	50.79	40.56	7.73	0.83	0.09
15	50.85	43.24	5.42	0.43	0.06
20	50.22	45.33	4.29	0.15	0.01
25	50.46	45.61	3.79	0.14	0
30	49.85	46.81	3.29	0.05	0
35	49.56	47.95	2.45	0.03	0.01
40	50.38	47.26	2.31	0.05	0
45	49.98	47.6	2.37	0.05	0
50	49.96	48.07	1.95	0.02	0

Kako je vidljivo iz dijagrama (*Slika 4.16*) i tablice (*Tablica 4.8*), vjerojatnosti nula ili jednog uzastopnog ponavljanja konvergiraju prema vrijednosti 50%. Suprotno tome, vjerojatnosti većeg broja uzastopnih ponavljanja – dva, tri te četiri i više – konvergiraju prema vrijednosti 0%. Na temelju takve raspodjele možemo zaključiti da je s povećanjem broja stanja i upotrebom Markovljevih lanaca višeg reda moguće s visokom sigurnošću oblikovati prijelazne matrice na koje ne utječe uzastopno ponavljanje elemenata skupa stanja.

No kao što je već napomenuto, uzastopno ponavljanje tek je jedan dio problema. Potrebno je ispitati i drugi utjecajni faktor tj. ponavljanje sekvenci.

4.3.4. Iskoristivost lanaca

Iskoristivost znači da je red Markovljeva lanca primjenjiv na određeni niz slučajnih brojeva. Primjenjivost podrazumijeva mogućnost tvorbe istovjetnog niza iz vrijednosti pohranjenih u matrici prijelaznih vrijednosti. To se događa samo kada je u svakom retku matrice maksimalno jedan element te su vrijednosti na dijagonali jednake 0. Vrijednosti na dijagonali predstavljaju ponavljanje istovjetnih elemenata (primjerice 2-2-2-2) kada prijelazne vrijednosti daju rješenje u obliku beskonačnog ponavljanja tog elementa. Na temelju simuliranih nizova možemo ispitati iskoristivost različitih redova Markovljeva lanca na nizovima sastavljenim od različitih brojeva stanja. Proveden je eksperiment na deset različitih uzoraka i prikazane vrijednosti predstavljaju srednje vrijednosti tih uzoraka. Svaki se uzorak sastoji od 1000 stohastičkih lanaca.

Rezultat eksperimenta prikazan je u obliku iskoristivosti određenog reda prijelazne matrice izraženog u postotcima. Izraženi postotak je udio prijelaznih matrica kojima je moguće jednoznačno replicirati inicijalni niz na temelju kojeg je oblikovana prijelazna matrica u ukupnom broju lanaca. Vrijeme obrade je vremenski interval potreban da se uz pomoć računala na temelju 1000 stohastičkih lanaca proizvoljne dužine oblikuje istovjetan broj prijelaznih matrica.

Tablica 4.9. *Iskoristivost i vrijeme obrade različitih redova Markovljeva lanca.*

Broj stanja	Iskoristivost, %				Vrijeme obrade, s			
	1. red	2. red	3. red	4. red	1. red	2. red	3. red	4. red
5	39.28	70.56	88.20	95.08	0.021	0.018	0.018	0.017
10	30.12	67.92	92.82	98.95	0.022	0.021	0.030	0.115
15	25.76	66.72	94.54	99.48	0.028	0.024	0.088	1.339
20	21.90	66.76	95.50	99.72	0.028	0.033	0.241	10.013
25	21.34	66.30	96.82	99.85	0.028	0.047	0.828	33.506
30	19.88	67.98	97.28	99.90	0.024	0.068	3.026	111.848
35	17.78	66.60	97.26	99.96	0.031	0.102	5.607	256.980
40	17.94	66.06	98.10	-	0.037	0.115	9.546	-
45	16.06	67.10	97.84	-	0.033	0.154	15.507	-
50	15.78	66.84	98.28	-	0.030	0.204	23.519	-

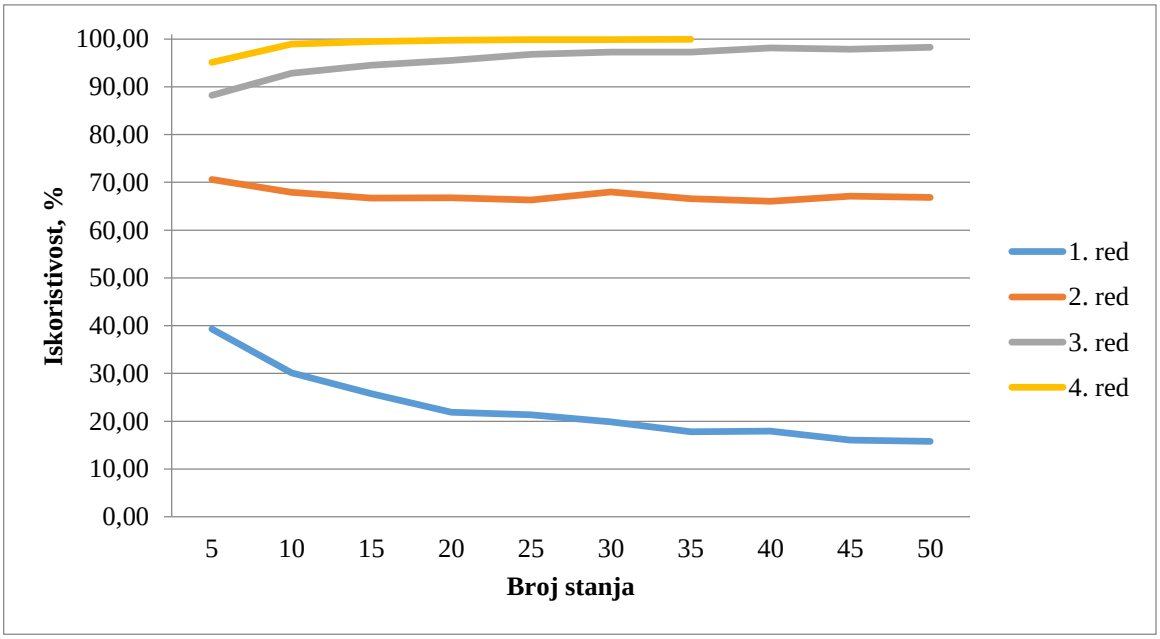

Slika 4.17. *Iskoristivost različitih redova Markovljeva lanca.*

Na temelju iskoristivosti i vremena obrade možemo procijeniti adekvatan red Markovljeva lanca. Kako je prikazano rezultatima (*Tablica 4.9*), niži redovi, prvi i drugi, imaju ograničenu primjenjivost uslijed znatno niže iskoristivosti prijelaznih matrica. Viši redovi, treći i četvrti, imaju puno bolju stopu iskoristivosti te su primjereniji za primjenu u modelu. No uza stopu

iskoristivosti ograničavajući faktor je računska složenost koja je u ovom eksperimentu iskazana kao vrijeme potrebno za obradu tisuću lanaca. Kako je vidljivo iz rezultata, računska složenost i postotak iskoristivosti su oprečne vrijednosti i porastom jedne raste i druga. Zbog toga je nužno odabrati stupanj složenosti koji omogućava izvođenje u realnom vremenu uz zadovoljavajući postotak iskoristivosti. Na temelju izmjerenih podataka odabire se Markovljev lanac trećeg reda kao osnova vjerojatnosnog modela.

5. Eksperimentalna validacija

No amount of experimentation can ever prove me right; a single experiment can prove me wrong.

Albert Einstein

U eksperimentalnoj fazi istraživanja razvijena metodologija verificirana je, s ciljem potvrde hipoteze, nizom odabranih problema. U Laboratoriju za projektiranje izradbenih i montažnih sustava Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu provedeni su pokusi na realnom sustavu koji čine robotska ruka s integriranim senzorima momenata i upravljačkom jedinicom, računalo, kao i „umjetna koža", koja ima mogućnost razlučivanja ljudskog dodira i neposredne blizine prije svega biološkog materijala.

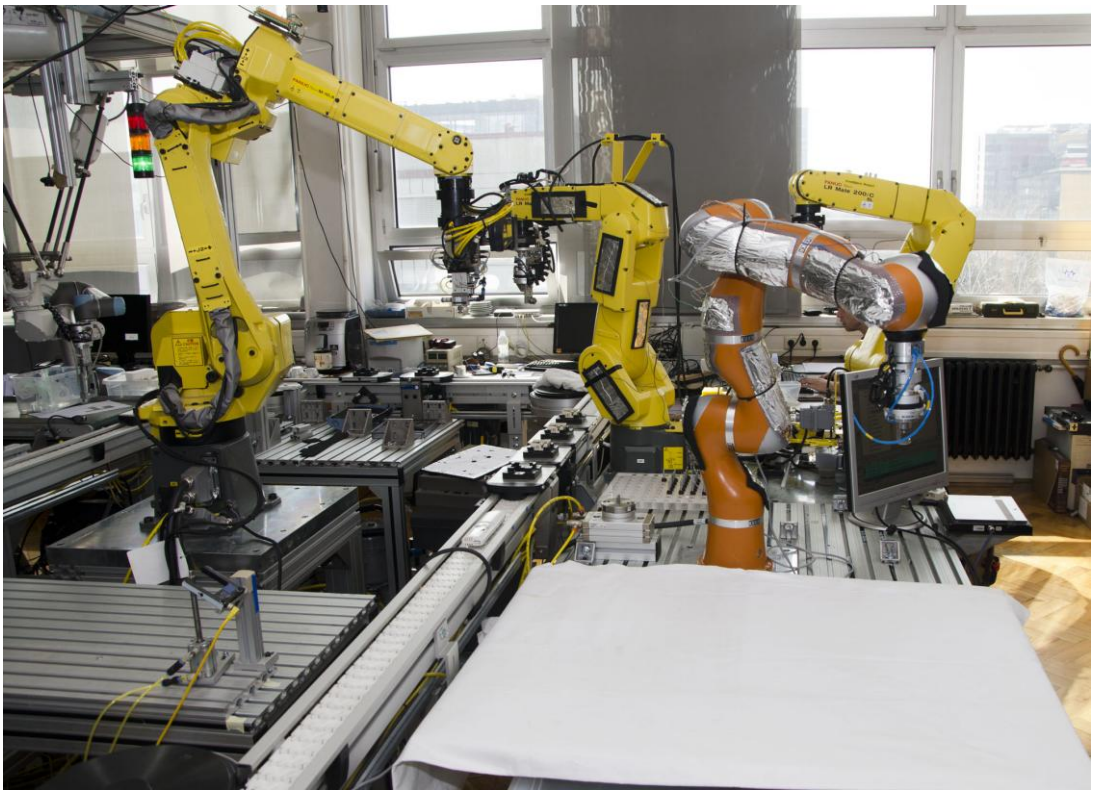

Slika 5.1. *Oprema korištena pri provedbi eksperimenata.*

5.1. Validacija tumačenja taktilne interakcije

Temeljni uvjet za procjenu djelotvornosti tumačenja taktilne interakcije je provedba ispitivanja ciljanog elementa na temelju sirovih podataka (pomak, brzina, sila) validacijskih mjerenja. Na temelju podataka provodi se validacija klasifikacija potrebnih za razaznavanje događaja. Validacija se provodi na dva izdvojena eksperimenta:

– klasifikacije brzine i

– gesta pokretom.

Cilj prvog eksperimenta je odrediti točnost klasifikacije brzine na temelju ostvarenih kretnji korisnika. Točnost klasifikacijske metode izražava podudaranje dobivenih rezultata s

unesenim kretanjem. Pod pojmom uneseno kretanje podrazumijeva se kretanje koje, prema kriterijima korisnika koji ostvaruje kretanje, spada u određenu skupinu. Provodi se na pet različitih tipova unesenih elementarnih kretnji uz deset ponovljenih mjerenja svakog uzorka tipova. U eksperimentu se promatra klasifikacija u skupine ostvarenih brzina. Pokus je invarijantan na smjer kretanja. Tako je rezultat klasifikacije jedan parametar – brzina. Vrijednosti odstupanja razaznate od stvarne, unesene, iskazuju se kao numeričke vrijednosti količine uzoraka.

Tablica 5.1. *Rezultat klasifikacije brzine na temelju kretnje korisnika.*

Kretnja korisnika	Klasificirana brzina			Broj testova
	Sporo	Brzo	Trzaj	
kratko sporo	10	0	0	10
dugo sporo	10	0	0	10
kratko brzo	0	10	0	10
dugo brzo	0	9	1	10
trzaj	0	10	0	10

Svrha validacije je dokazati prikladnost klasifikacijske metode za razaznavanje brzine segmenata koje je unio korisnik. Analizom vrijednosti, s obzirom na visoki postotak uspješno klasificiranih, donosi se zaključak da je metoda klasifikacije vrlo pouzdana. Takav je rezultat u skladu s očekivanjem s obzirom na male greške dvokriterijske klasifikacije brzine pokreta na temelju prosječnih i maksimalnih sila.

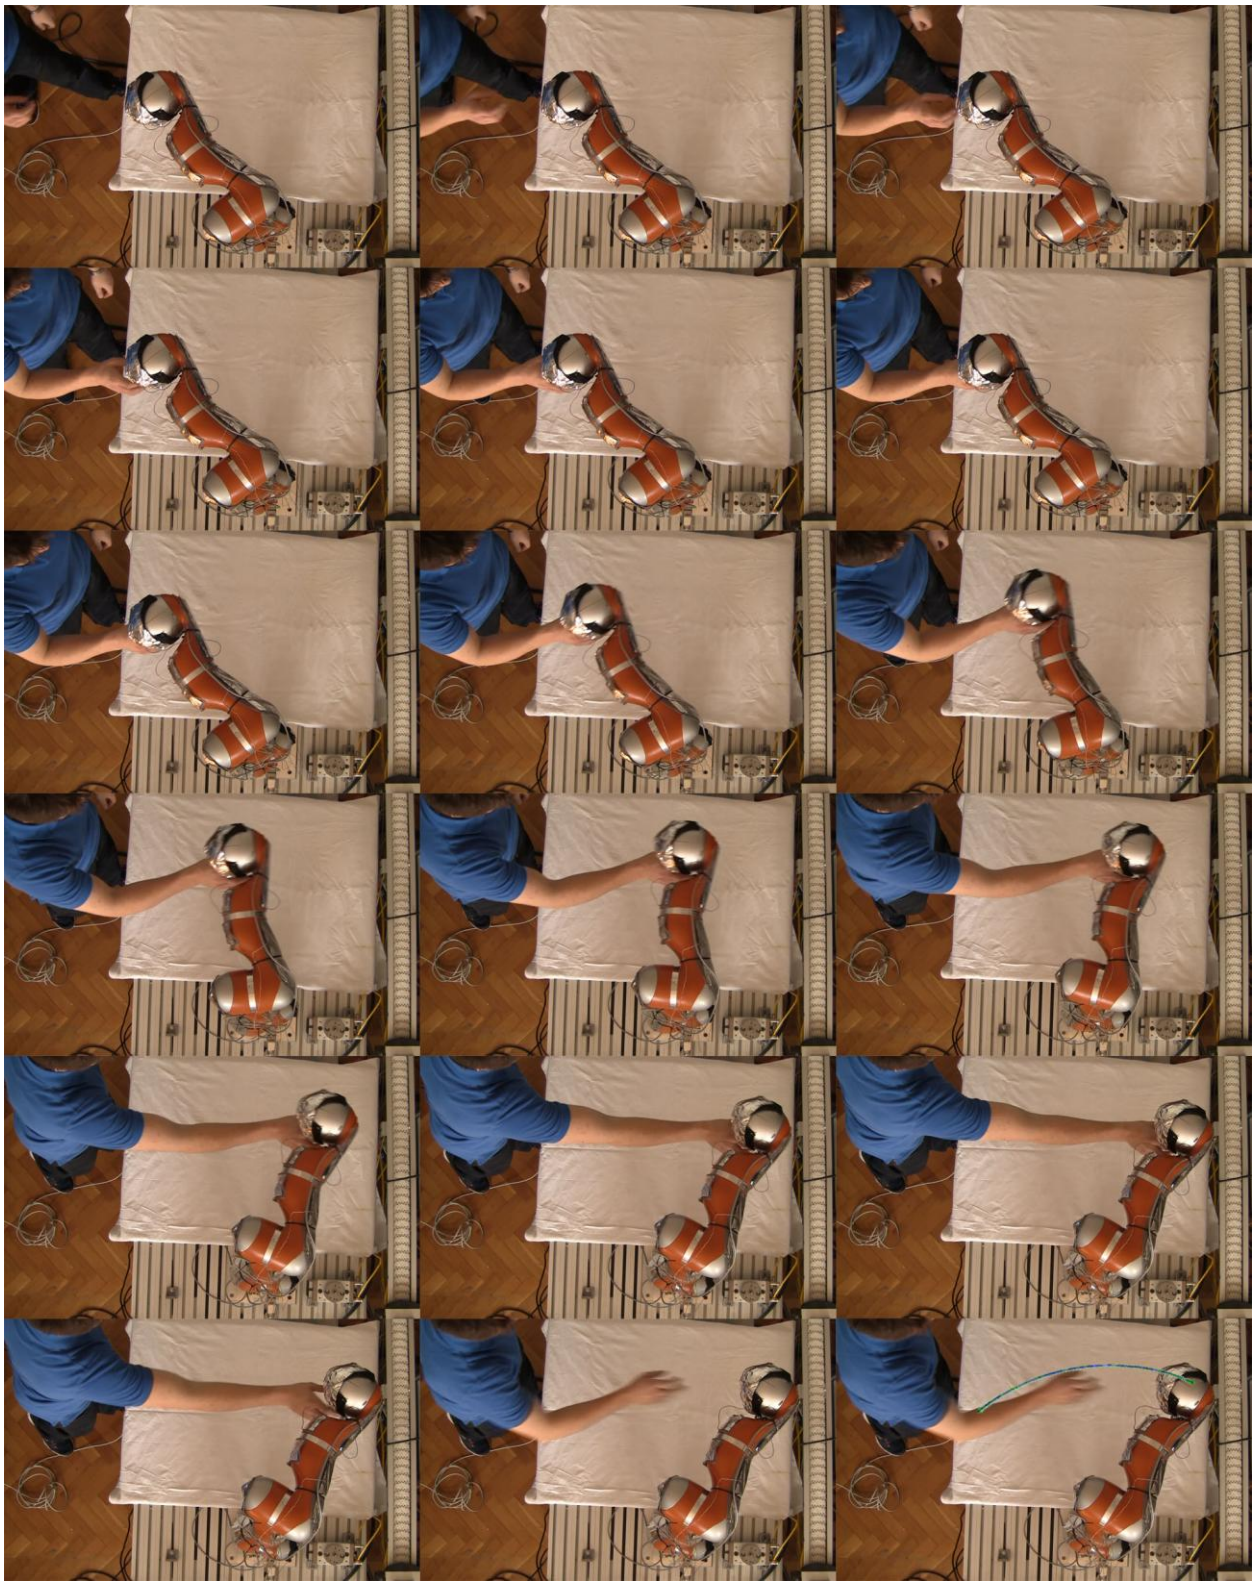

Slika 5.2. *Eksperiment klasifikacije brzine na temelju ostvarenih kretnji.*

U drugom slučaju testirane su geste koje se temelje na pokretu. Geste pokretom sačinjene su od dviju komponenata – brzine pokreta i smjera. Izdvojena je gesta operacije odlaganja, koja je sačinjena od dvaju elementa i kratkog vremenskog razmaka. Gestu čini brzi pokret

vertikalno prema dolje, popraćen brzim pokretom vertikalno prema gore s kratkim vremenskim intervalom između dvaju segmenata (BD – KT – BG).

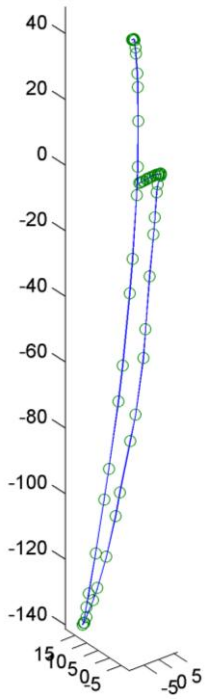

Slika 5.3. *Putanja geste BD - KT – BG.*

Na temelju iznosa apsolutnih brzina radi se segmentacija dijelova kretanja.

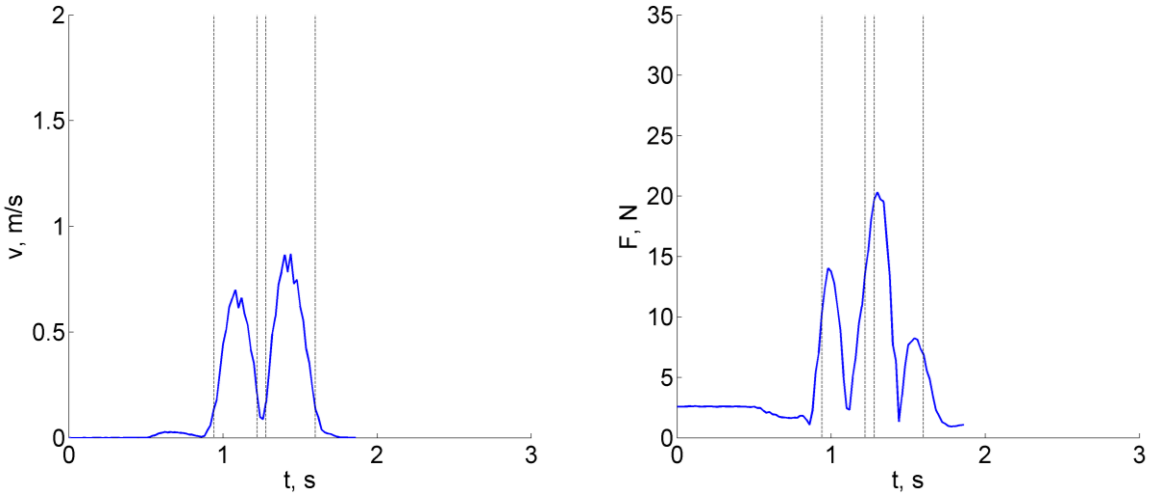

Slika 5.4. *Segmenti pokreta geste BD – KT – BG.*

Potom se na temelju dvokriterijskog modela klasifikacije brzine pokreta na temelju prosječnih i maksimalnih sila određuje kojoj skupini brzine svaki segment kretanja pripada.

Uz klasifikaciju brzine potrebno je odrediti i smjer kretnje. On se određuje na temelju početne i konačne točke svakog segmenta, uz pomoć postavljenih separacijskih funkcija pomaka.

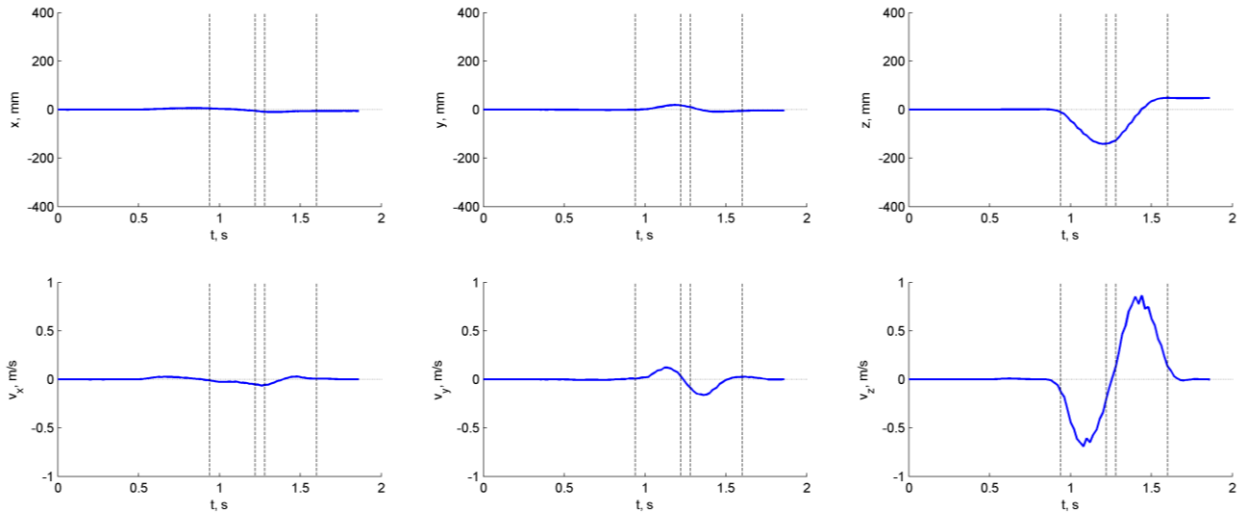

Slika 5.5. *Parametri pokreta geste BD – KT – BG po komponentama.*

Na uzorku od deset pokušaja jedan je slučaj pogrešno klasificiran. Pogrešno klasificirani slučaj protumačen je kao slijed brzog prostornog pomaka, kratkog vremenskog intervala i brzog pomaka prema gore (BP – KT – BG). Analizom pogrešno klasificiranog segmenta utvrđeno je da je u slučaju malih pomaka moguća pogrešna klasifikacija vertikalne putanje. Posebice prilikom naglih promjena smjera koje se odvijaju pri brzoj izmjeni smjerova kretanja, vertikalno dolje i vertikalno gore, nesvjesno se dodaje horizontalna komponenta koja u određenim slučajevima može uzrokovati pogrešnu klasifikaciju i nemogućnost ispravnog razaznavanja unesene geste.

5.2. Oblikovanje slijeda djelovanja

Eksperiment oblikovanja slijeda djelovanja provest će se na primjeru izuzimanja i odlaganja predmeta rada. Namjera korisnika je premjestiti predmet s jednog mjesta na drugo u zajedničkom radnom prostoru čovjeka i robota.

Klasičan pristup zadavanja takvog zadatka robotu je programiranje uz pomoć upravljačke konzole. Tipkama na upravljačkoj konzoli čovjek upravlja prostornim položajem vrha robotske ruke, tj. središta alata. Pritom se nužni položaji u prostoru pritiskom na određenu tipku pohranjuju u upravljačkoj jedinici. Uz točke dodaju se i ostali potrebni programski elementi – način kretanja, brzine, naredbe hvataljke itd.

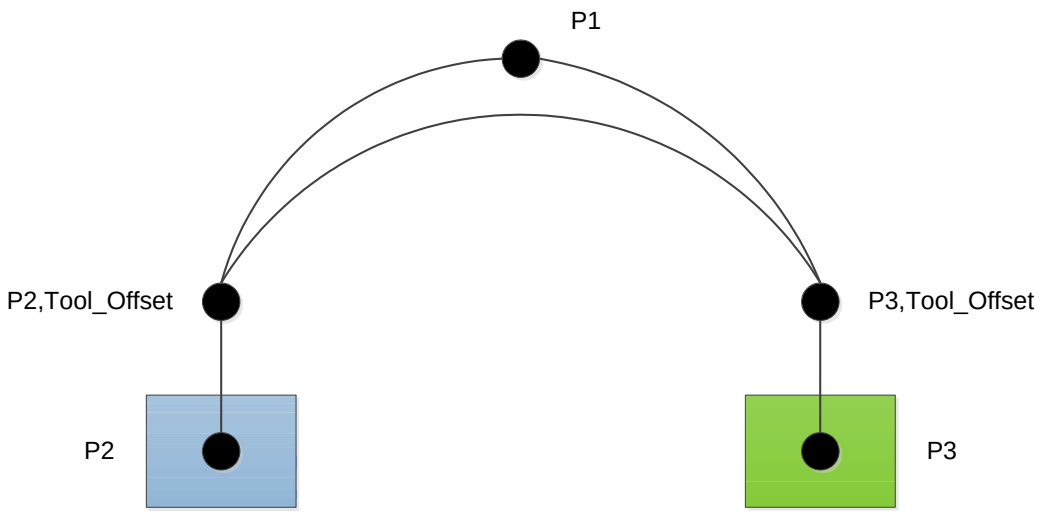

Slika 5.6. *Izuzimanje i odlaganje predmeta.*

Algoritam 3.1 prikazuje programski kod unesen uz pomoć upravljačke konzole čija je shema prikazana na slici (*Slika 5.6*).

Algoritam 5.1. *Uzmi i stavi program.*

Algoritam:

`1: CALL GR_OPEN`	Otvaranje hvataljke
`2: J P[1] 100% FINE`	Početna točka u programu
`3: J P[2] 100% FINE: Tool_Offset`	Točka prilaska
`4: L P[2] 100mm/sec FINE`	Točka hvatanja
`5: CALL GR_CLOSE`	Zatvaranje hvataljke
`6: L P[2] 100mm/sec FINE: Tool_Offset`	Povratak u točku prilaska
`7: J P[1] 100% CNT50`	Interpolacijska točka (početna točka)
`8: J P[3] 100% FINE: Tool_Offset`	Točka prilaska odlaganju
`9: L P[3] 100mm/sec FINE`	Točka odlaganja
`10: CALL GR_OPEN`	Otvaranje hvataljke
`11: L P[3] 100mm/sec FINE: Tool_Offset`	Povratak u točku prilaska
`12: J P[1] 50% FINE`	Povratak u početnu točku programa

Primjenom modela interakcije omogućava se znatno jednostavnije oblikovanje slijeda djelovanja. Čovjek prenosi svoju namjeru robotu putem fizičke interakcije. Odgovarajuće radnje prenose se robotu uz pomoć seta gesti kojima se pozivaju različite unaprijed programirane vještine za hvatanje i odlaganje na ciljanim mjestima. Gestama se oblikuju tri potrebne komponente za izvršavanje zadatka: putanje, izuzimanje i odlaganje. Nakon što je

čovjek pokazao željene radnje, robot je u stanju reproducirati korake kroz prostor stanja. Ovaj zadatak predstavlja primjer složenog zadatka koji se gradi iz jednostavnih segmenata – njihovim spajanjem tvore se složeniji zadatci.

Eksperiment se provodi pet puta na istim elementima u prostoru. Na radnu plohu postavljen je predmet rada koji treba izuzeti, a potom odložiti. Položaj mjesta odlaganja i izuzimanja je u svakom eksperimentu jednak. I početna je točka u prostoru u svim eksperimentima na istome mjestu. Slijed djelovanja sastoji se od pet koraka:

1. Putanja od početne točke do točke izuzimanja
2. Izuzimanje predmeta
3. Putanja od točke izuzimanja do točke odlaganja
4. Odlaganje predmeta
5. Povratna putanja.

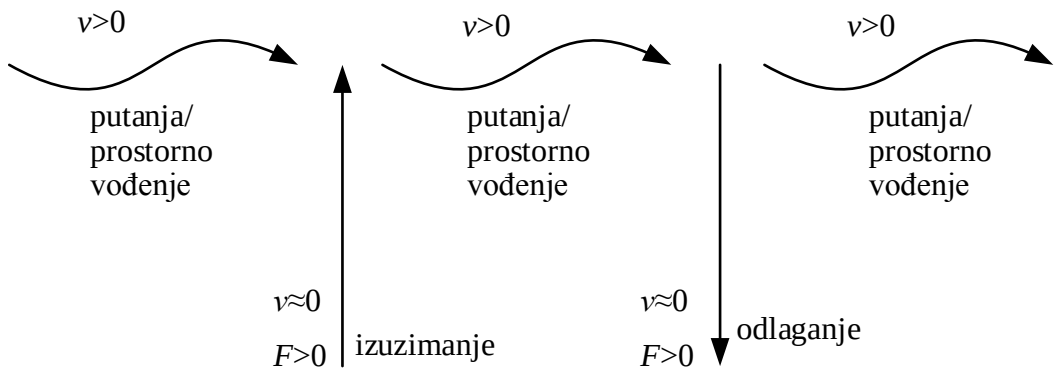

Slika 5.7. *Oblikovanja slijeda djelovanja fizičkom interakcijom.*

Uz pomoć elementa taktilne interakcije razaznaju se segmenti i potom se klasificiraju na temelju parametara. Segmenti koji predstavljaju putanje tj. prostorno vođenje mogu se definirati gestama sporog ili brzog vođenja (SH / SG / SD / SP / BH / BG / BD / BP). Segmenti koji predstavljaju izuzimanje i odlaganje predmeta razaznaju se u fiksnom položaju u prostoru na temelju komponenata sile. Velika sila vertikalno u smjeru prema gore tj. od podloge (FVG) označava izuzimanje predmeta, a prema podlozi (FVD) označava odlaganje. Elektroda kapacitivnog senzora K12 ima funkciju izmjene režima rada robota između popustljivog i čvrstog načina djelovanja. Aktivacijom elektrode obavlja se promjena režima rada, što omogućava brzu promjenu prilikom rada.

Slika 5.8 prikazuje primjer oblikovanih putanja u jednom od uzoraka. Točke na jednakom vremenskom razmaku ukazuju na brzinu kretanja. Iz prikaza se može uočiti kako su točke gusto grupirane na dva mjesta u prostoru koja naznačuju mjesta izuzimanja i odlaganja.

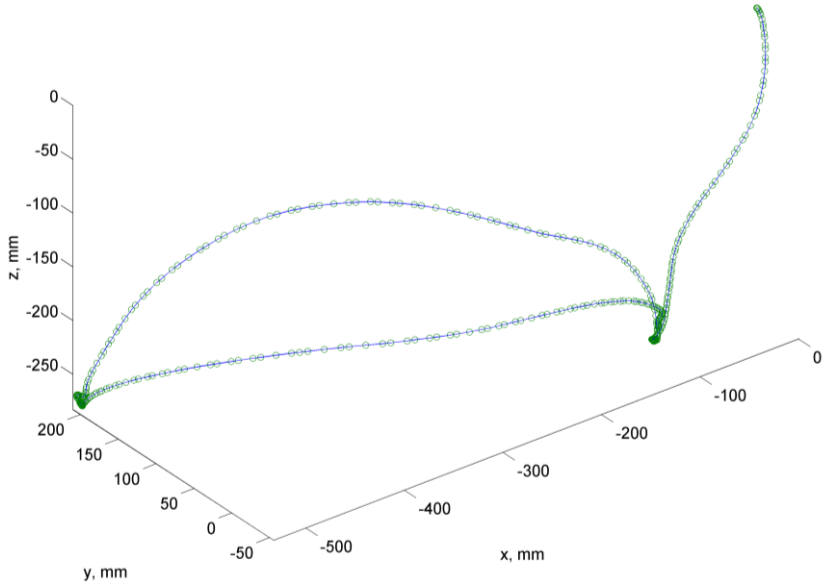

Slika 5.8. *Oblikovane putanje.*

Na temelju parametara pojedinih uzoraka, brzine pokreta u popustljivom režimu te sile prilikom čvrstog režima rada, određuju se segmenti. Svaki uzorak je na temelju segmentacije ispravno razložen u tri segmenta pokreta i dva segmenta sile u stacionarnom stanju.

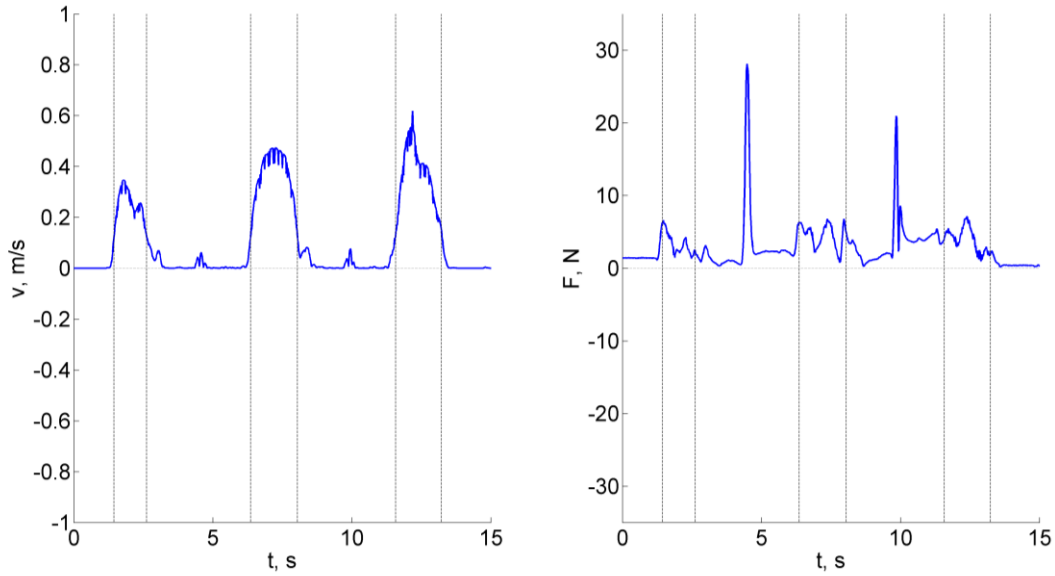

Slika 5.9. *Segmenti pokreta.*

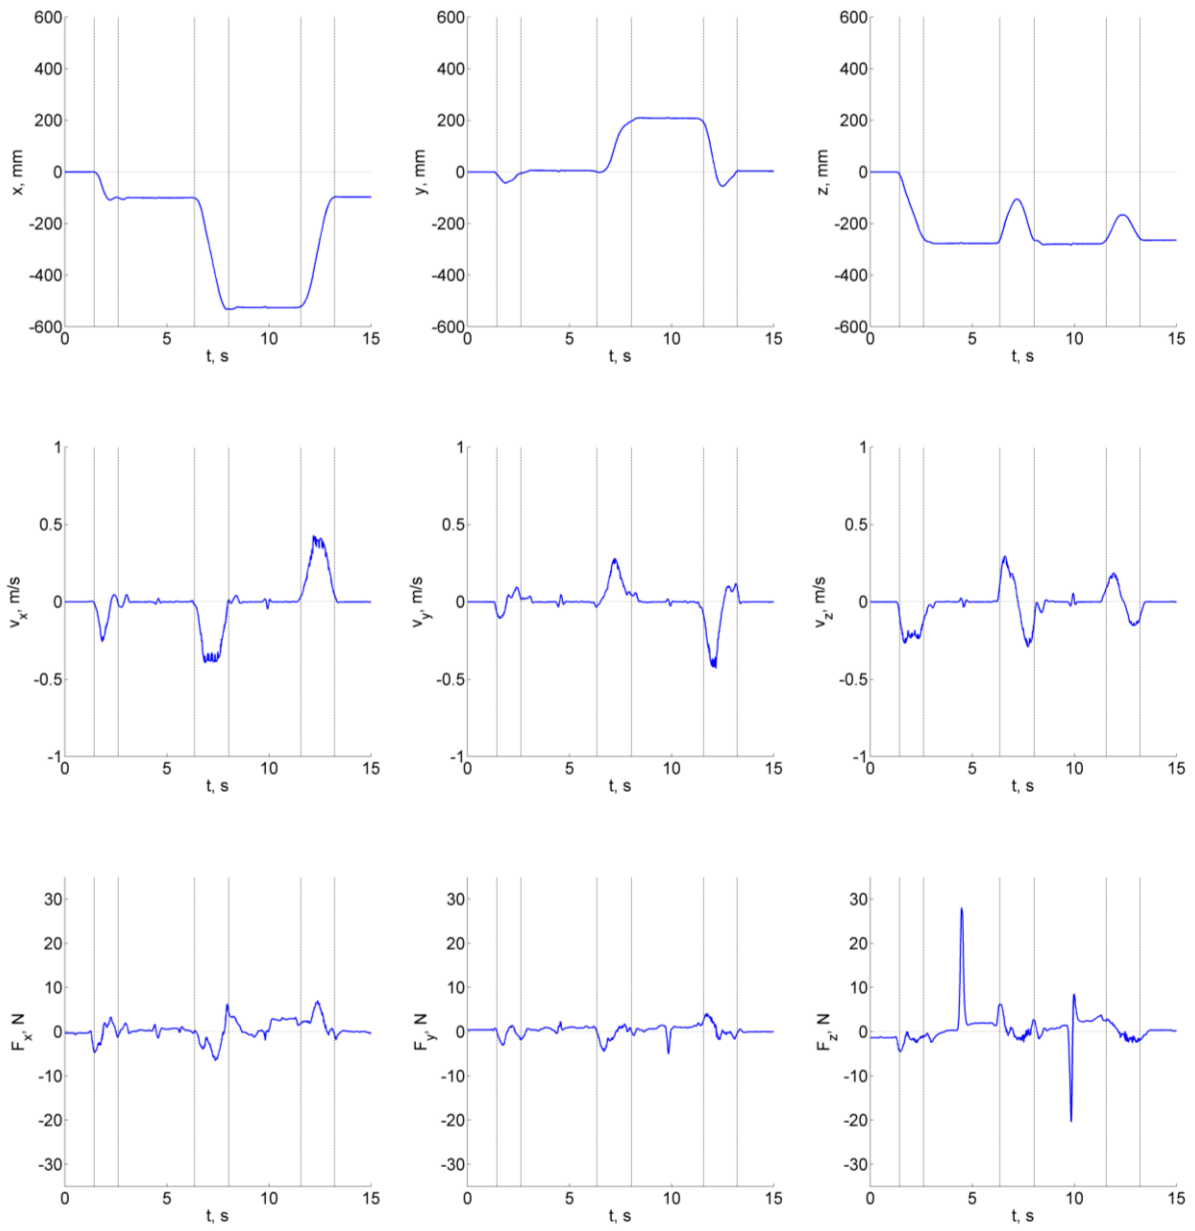

Slika 5.10. *Parametri pokreta po komponentama*.

Na temelju parametara za svaki se segment klasificira njegova brzina i pomak kako bi se mogla razlučiti unesena gesta korisnika. U eksperimentu su kod svih pet uzoraka izdvojena tri segmenta kretanja s pripadajućim vrijednostima. Na temelju srednje vrijednosti i maksimalne vrijednosti sile na intervalu provodi se klasifikacija brzine segmenta. Na temelju pomaka, tj. promjene položaja, u horizontalnoj (xy) ravnini i vertikalnoj (z) osi klasificira se smjer kretanja. Na temelju dviju klasifikacija razaznaje se gesta.

Tablica 5.2. *Razlučene geste segmenata pokreta na temelju parametara*.

Uzorak	Segment	$\bar{F}$, N	Max F, N	Brzina segmenta	Horizontalna komponenta pomaka (xy), mm	Vertikalna komponenta pomaka (z), mm	Pomak segmenta	Razlučena gesta
1	1	5,20	10,66	S	130,68	171,84	P	SP
1	2	3,78	6,08	S	463,76	16,15	H	SH
1	3	2,91	3,21	S	472,02	8,95	H	SH
2	1	2,66	5,36	S	99,11	217,21	P	SP
2	2	2,23	6,69	S	468,17	11,14	H	SH
2	3	3,57	5,71	S	477,61	7,11	H	SH
3	1	3,30	6,62	S	99,90	247,20	P	SP
3	2	4,46	6,80	S	473,17	22,45	H	SH
3	3	3,99	7,12	S	462,85	12,89	H	SH
4	1	3,18	6,76	S	93,56	263,56	P	SP
4	2	3,85	7,86	S	469,26	35,82	H	SH
4	3	3,85	5,53	S	472,74	12,38	H	SH
5	1	3,50	4,88	S	127,13	262,83	P	SP
5	2	4,23	6,67	S	474,93	25,50	H	SH
5	3	4,29	7,47	S	464,56	12,29	H	SH

Uza segmente pokreta potrebno je izdvojiti i segmente u kojima se javlja sila, a robot se ne kreće. U stacionarnom stanju klasifikacija se radi isključivo na temelju sile. S obzirom na iznos vanjske sile radi se podjela u dvije skupine na mali i veliki iznos vanjske sile. Na temelju parametara sile određuju se segmentni svakog uzorka. Potom se svaki segment klasificira s obzirom na iznos sile kako bi se mogla razlučiti unesena gesta korisnika. U eksperimentu su kod svih pet uzoraka izdvojena dva segmenta kretanja s pripadajućim vrijednostima. Na temelju maksimalne vrijednosti sile na intervalu radi se klasifikacija sile segmenta. Na temelju komponenata sile, F_x, F_y, F_z, određuje se smjer sile. Na temelju klasifikacije razaznaje se gesta.

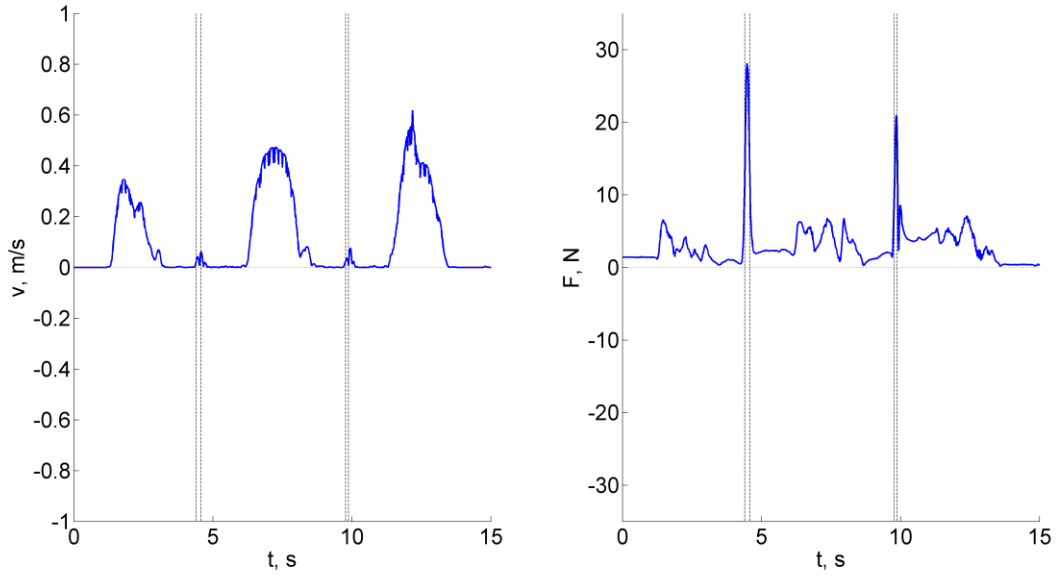

Slika 5.11. *Segmenti sile u stacionarnim stanjima.*

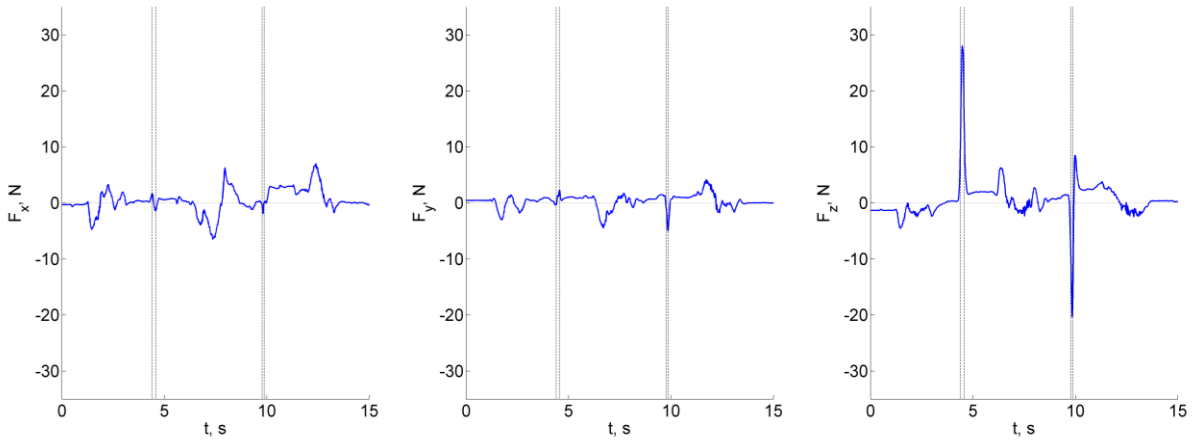

Slika 5.12. *Komponente sile.*

Tablica 5.3. *Razlučene geste u stacionarnim stanjima.*

Uzorak	Segment	Max F, N	Smjer	Razlučena gesta
1	1	26,04	+z	FVG
1	2	31,66	-z	FVD
2	1	31,74	+z	FVG
2	2	22,76	-z	FVD
3	1	28,15	+z	FVG
3	2	20,97	-z	FVD
4	1	32,43	+z	FVG

4	2	23,60	-z	FVD
5	1	30,99	+z	FVG
5	2	28,69	-z	FVD

U slučaju svih pet uzoraka uspješno je oblikovana sekvenca:

SP – FVG – SH – FVD – SH.

Na temelju takvog slijeda događaja oblikuje se lanac stanja i pripadajuća prijelazna matrica.

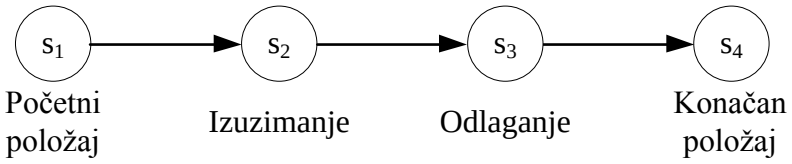

Slika 5.13. *Lanac stanja eksperimenta.*

U sloj putanja višekriterijske interpretacije prostora zapisuju se oblikovane putanje kako bi se mogle upotrijebiti prilikom reproduciranja koraka kroz prostor stanja. Na temelju stanja prostora, prepreke i položaja čovjeka oblikuje se matrica dostupnosti

$$D = \left(d_{ij}\right)\ i \in \{1, 2, \ldots, k\}, j \in \{1, 2, \ldots, l\} \qquad (5.1)$$

koja sadrži vjerojatnosti koje opisuju mogućnost prostorne kretnje od stanja *i* do stanja *j*.

Na temelju umnožaka pojedinih elemenata konačne prijelazne matrice P i matrice dostupnosti D

$$M = (p_{ij} \times d_{ij})\ i \in \{1,2,\ldots,k\}, j \in \{1,2,\ldots,l\}, \qquad (5.2)$$

oblikuje se konačna matrica modela M na temelju svih navedenih komponenata.

5.3. Autonomno djelovanje

Robot stvara planove poštujući ograničenja repliciranjem radnji koje je oblikovao korisnik. Na temelju demonstracije oblikovani su prethodni sljedovi djelovanja koji se potom pokušavaju replicirati. U skalu sa sekvencama djelovanja zapisuju se matrice prijelaznih vjerojatnosti. Vremenskim otežavanjem radi se raspodjela vjerojatnosti. S obzirom na broj sekvenci koje su uslijedile, pojedinoj se sekvenci pridaje određena vjerojatnost. Na temelju takve raspodjele oblikuje se konačna raspodjela. No s obzirom na trenutno stanje prostora postoje određene varijacije i odstupanja od repliciranja idealne sekvence.

U eksperimentu se analizira slučaj koji se zasniva na trima prethodnim obrascima djelovanja:

t-1	1	2	3	4	5	6
t-2	1	4	5	6		
t-3	1	2	3	6		

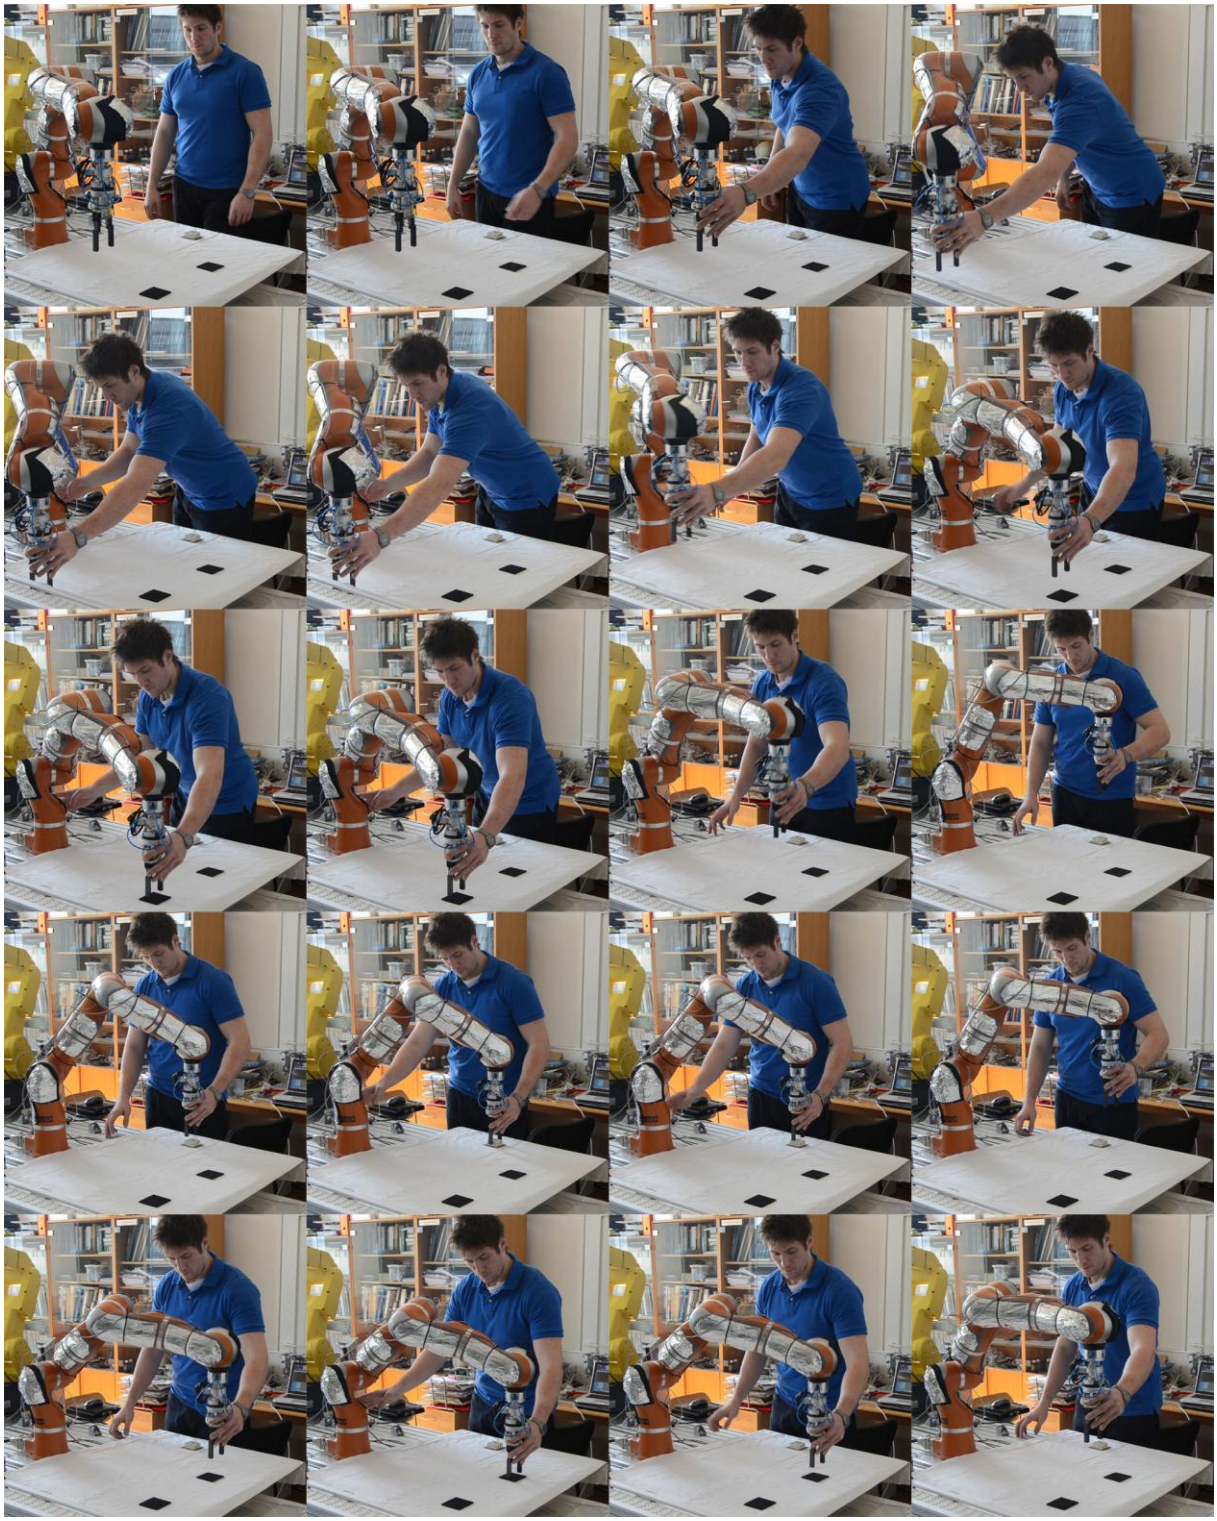

Slika 5.14. *Oblikovanje obrasca djelovanja.*

Ovako definirani obrasci djelovanja predstavljaju izvođenje dva „uzmi – odloži” zadatka. Prvi je izuzimanje s radnog mjesta s_2 i odlaganje na s_3. Drugi je izuzimanje s mjesta s_4 i odlaganje na s_5. Stanja s_1 i s_6 su simbolična stanja koja označavaju početak i kraj djelovanja te nemaju određen prostorni položaj, tj. prostorno su nezavisni. U sekvenci t-1 oba zadatka su spojena u jednu cjelinu kako bi se slijedno izvele obje operacije.

Kroz eksperimente se provodi analiza rješenja koje pruža vjerojatnosni model s obzirom na dva utjecajna faktora: baza eksponenta λ vremenskog otežavanja i prostorni utjecaj kroz matricu dostupnosti D. Analizirat će se dva slučaja, kada u radnom prostoru nema prepreka, i u drugom slučaju, kada prisutnost čovjeka onemogućava pristup jednom cilju koji je dio sekvence (*Slika 5.15*).

Na temelju sekvenci t-1, t-2 i t-3 oblikuju se tri prijelazne matrice trećeg reda: P_{t-1}, P_{t-2} i P_{t-3}.

S obzirom na broj stanja u eksperimentu (n = 6) i treći red lanca modela prijelazne matrice su dimenzija 216 × 6 (redaka × stupaca). Potom se sumiraju umnošci faktora i prijelaznih matrica

$$P_{sum} = P_{t-1} \times \lambda^0 + P_{t-2} \times \lambda^1 + P_{t-3} \times \lambda^2 \qquad (5.3)$$

te se nakon toga matrica P_{sum} normira tako da vrijednosti sume elemenata svakog retka iznose jedan. Na temelju prostornog planiranja oblikuje se matrica dostupnosti D pojedinih stanja ovisno o njihovom prostornom položaju. Na temelju umnožaka pojedinih elemenata konačne prijelazne matrice P i matrice dostupnosti D

$$M = (p_{ij} \times d_{ij})\ i \in \{1, 2, \ldots, k\}, j \in \{1, 2, \ldots, l\}, \qquad (5.4)$$

oblikuje se konačna matrica modela M.

Vjerojatnost prelaska u sljedeće stanje dobivamo množenjem trenutnog stanja sustava u obliku vektora x s matricom modela M, u obliku vektora $P_{sa-sb-sc} = xM$, s komponentama P_{sx}. Na temelju najveće vrijednosti max $P_{sa-sb-sc}$ odabire se prijelaz u sljedeće stanje.

Polazna točka svakog eksperimenta je stanje s_1. Sva daljnja stanja odabiru se na temelju vrijednosti vjerojatnosti prelaska. S obzirom na broj stanja dimenzija vektora je 216 elemenata, a sve su vrijednosti jednake nuli osim trenutnog stanja, koje nosi vrijednost jedan.

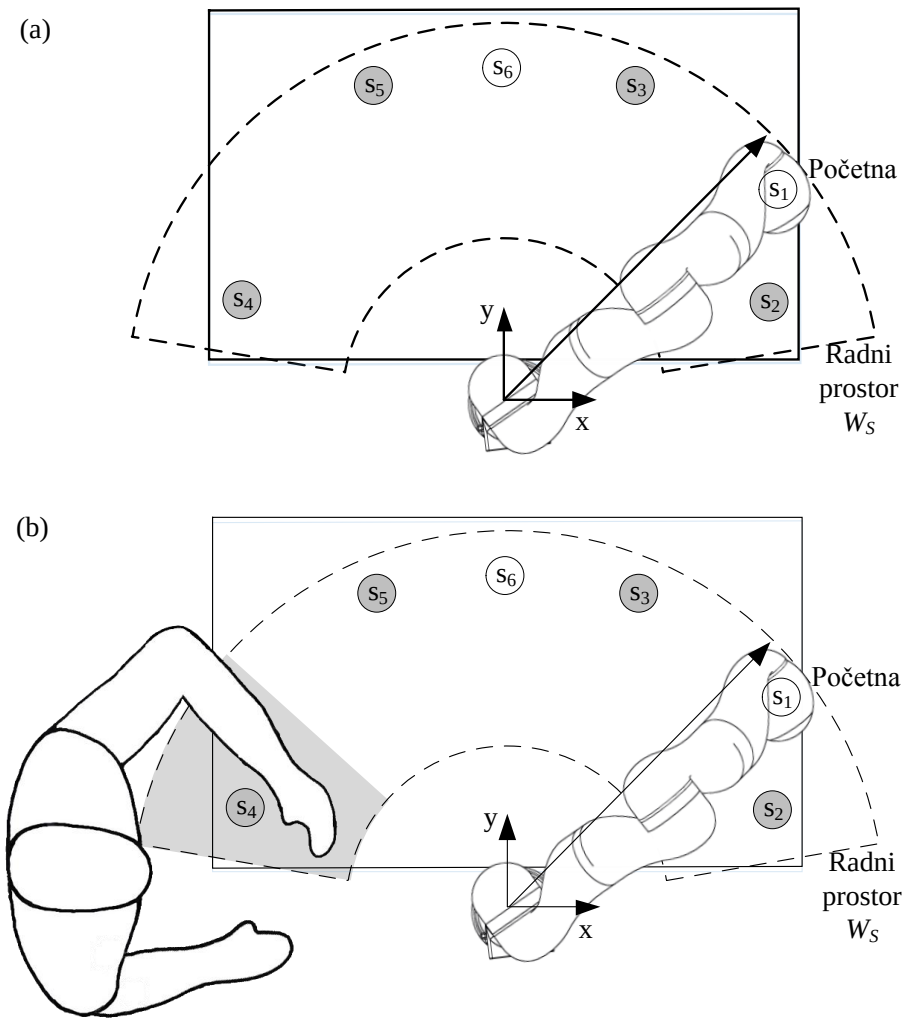

Slika 5.15. *Radni prostor: a) slobodan, b) s čovjekom u radnom području.*

5.3.1. Slobodan radni prostor

Eksperiment je proveden s nekoliko različitih faktora vremenskog otežavanja (λ), prvo na slučaju kada u prostoru nema prepreka. Lanac počinje iz početnog stanja s_1. S obzirom na treći red lanca kao opis uz trenutno stanje zapisuju se i dva prethodna stanja. U slučaju prvog stanja ne postoje prethodna stanja, pa se tada definiraju kao stanje s_1-s_1-s_1. Potom se računa umnožak

$$P_{s1-s1-s1} = xM = [0 \quad 0{,}67 \quad 0 \quad 0 \quad 0{,}33 \quad 0]. \tag{5.5}$$

Na temelju najveće vrijednosti odabire se prelazak u stanje s_2. Adekvatno se oblikuje vrijednost vektora x i ponovno se računa umnožak koji u ovom slučaju ima vrijednosti. Proces se na istovjetan način ponavlja sve do dolaska u konačno stanje s_6. Rezultati eksperimenta za

različite faktore vremenskog otežavanja prikazani su tabličnim prikazom (*Tablica 5.4*). Vrijednosti P_{sx} dana je vjerojatnost prelaska iz trenutnog stanja u naredno stanje s_x.

Tablica 5.4. *Eksperiment – vrijednosti P_{sx} u ovisnosti o λ.*

$P_{sa-sb-sc}$	λ	P_{s1}	P_{s2}	P_{s3}	P_{s4}	P_{s5}	P_{s6}
$P_{s1-s1-s1}$	$\lambda = 1$	0	0,67	0	0,33	0	0
	$\lambda = 0{,}9$	0	0,67	0	0,33	0	0
	$\lambda = 0{,}5$	0	0,71	0	0,29	0	0
	$\lambda = 0{,}1$	0	0,91	0	0,09	0	0
$P_{s1-s1-s2}$	$\lambda \in [0,1]$	0	0	1	0	0	0
$P_{s1-s2-s3}$	$\lambda = 1$	0	0	0	0,5	0	0,5
	$\lambda = 0{,}9$	0	0	0	0,55	0	0,45
	$\lambda = 0{,}5$	0	0	0	0,8	0	0,2
	$\lambda = 0{,}1$	0	0	0	0,99	0	0,1
$P_{s2-s3-s4}$	$\lambda \in [0,1]$	0	0	0	0	1	0
$P_{s3-s4-s5}$	$\lambda \in [0,1]$	0	0	0	0	0	1

Na temelju vrijednosti u svim slučajevima oblikuje se sekvenca $s_1 - s_2 - s_3 - s_4 - s_5 - s_6$. Iznimka je slučaj $\lambda = 1$, kada su sve prošle sekvence jednakovrijedne te postoji vjerojatnost koja iznosi 50 % da se oblikuje sekvenca $s_1 - s_2 - s_3 - s_6$.

S obzirom na prethodne sekvence događaja, takav je ishod očekivan. Kako nema prostornih prepreka koje bi onemogućile pristup bilo kojem cilju, ovisno o težinskom faktoru vremenskog otežavanja, s manjom ili većom sigurnošću izvodi se posljednja sekvenca.

5.3.2. Zauzetost radnog prostora

U drugom eksperimentu položaj čovjeka u radnom prostoru predstavlja prepreke kretanju robota. Na temelju prisutnosti čovjeka oblikuje se matrica dostupnosti D. U slučaju viših redova lanaca matrica D je sastavljena od n^{red-1} manjih matrica D_E

$$D = \begin{pmatrix} D_E \\ D_E \\ \vdots \\ D_E \end{pmatrix}, \qquad (5.6)$$

koje se ponavljaju i predstavljaju prostorni prelazak od trenutnog stanja u prostoru do narednog stanja. U eksperimentu je stanje s_4 nedostupno iz svih preostalih stanja. Vrijednost p_d predstavlja vjerojatnost da je s_4 nedostupan iz bilo kojeg stanja u prostoru. Na temelju vrijednosti p_d oblikuje se matrica

$$D_E = \begin{pmatrix} 1 & 1 & 1 & p_d & 1 & 1 \\ 1 & 1 & 1 & p_d & 1 & 1 \\ 1 & 1 & 1 & p_d & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & p_d & 1 & 1 \\ 1 & 1 & 1 & p_d & 1 & 1 \end{pmatrix}. \tag{5.7}$$

U odsutnosti čovjeka koji predstavlja prepreku kretanju vrijednost $p_d = 1$, a u slučaju sigurne prepreke tj. čovjeka u radnom prostoru iznosi $p_d = 0$.

U eksperimentu je s obzirom na prethodne sekvence ključan prijelaz u stanju $s_1 - s_2 - s_3 - x$, gdje se u ovisnosti o faktorima p_d i λ razlikuje ishod sljedećeg stanja s_4 ili s_6.

U slučaju da je stanje s_4 potpuno nedostupno (p_d=0), oblikuje se sekvenca $s_1 - s_2 - s_3 - s_6$ na cijelom intervalu vrijednosti $\lambda \in \langle 0, 1]$ (*Tablica 5.5*).

Tablica 5.5. *Eksperiment:* $\lambda \in \langle 0, 1]$, $p_d = 0$.

	P_{s1}	P_{s2}	P_{s3}	P_{s4}	P_{s5}	P_{s6}
$P_{s1-s1-s1}$	0	1	0	0	0	0
$P_{s1-s1-s2}$	0	0	1	0	0	0
$P_{s1-s2-s3}$	0	0	0	0	0	1

O ostalim slučajevima u ovisnosti o intenzitetu prepreke i faktoru otežavanja moguća su različita djelovanja. Primjerice u slučaju $\lambda = 0{,}9$, $p_d = 0{,}25$ oblikuje se sekvenca $s_1 - s_2 - s_3 - s_4$ (*Tablica 5.6*).

Tablica 5.6. *Eksperiment:* $\lambda = 0{,}9$, $p_d = 0{,}25$.

	P_{s1}	P_{s2}	P_{s3}	P_{s4}	P_{s5}	P_{s6}
$P_{s1-s1-s1}$	0	0,89	0	0,11	0	0
$P_{s1-s1-s2}$	0	0	1	0	0	0
$P_{s1-s2-s3}$	0	0	0	0,24	0	0,76

No u eksperimentu na temelju definiranih prethodnih sekvenci (t-1, t-2, t-3) za svaku vrijednost $\lambda \in \langle 0, 1]$ postoji vrijednost $p_d \in [0, 1]$ koja daje granični slučaj kada je vrijednost vjerojatnosti za prelazak iz stanja s3 u stanje s4 i iz stanja s3 u konačno stanje s6 jednaka

$$P_{s1-s2-s3} = xM = [0 \quad 0 \quad 0 \quad 0{,}5 \quad 0 \quad 0{,}5]. \tag{5.8}$$

Također vrijedi i suprotno, za svaku vrijednost $p_d \in [0, 1]$ postoji vrijednost $\lambda \in \langle 0, 1]$. Primjerice kombinacije $\lambda = 0{,}1$ i $p_d = 0{,}01$ te $\lambda = 0{,}5$ i $p_d = 0{,}25$ rezultiraju takvim slučajem.

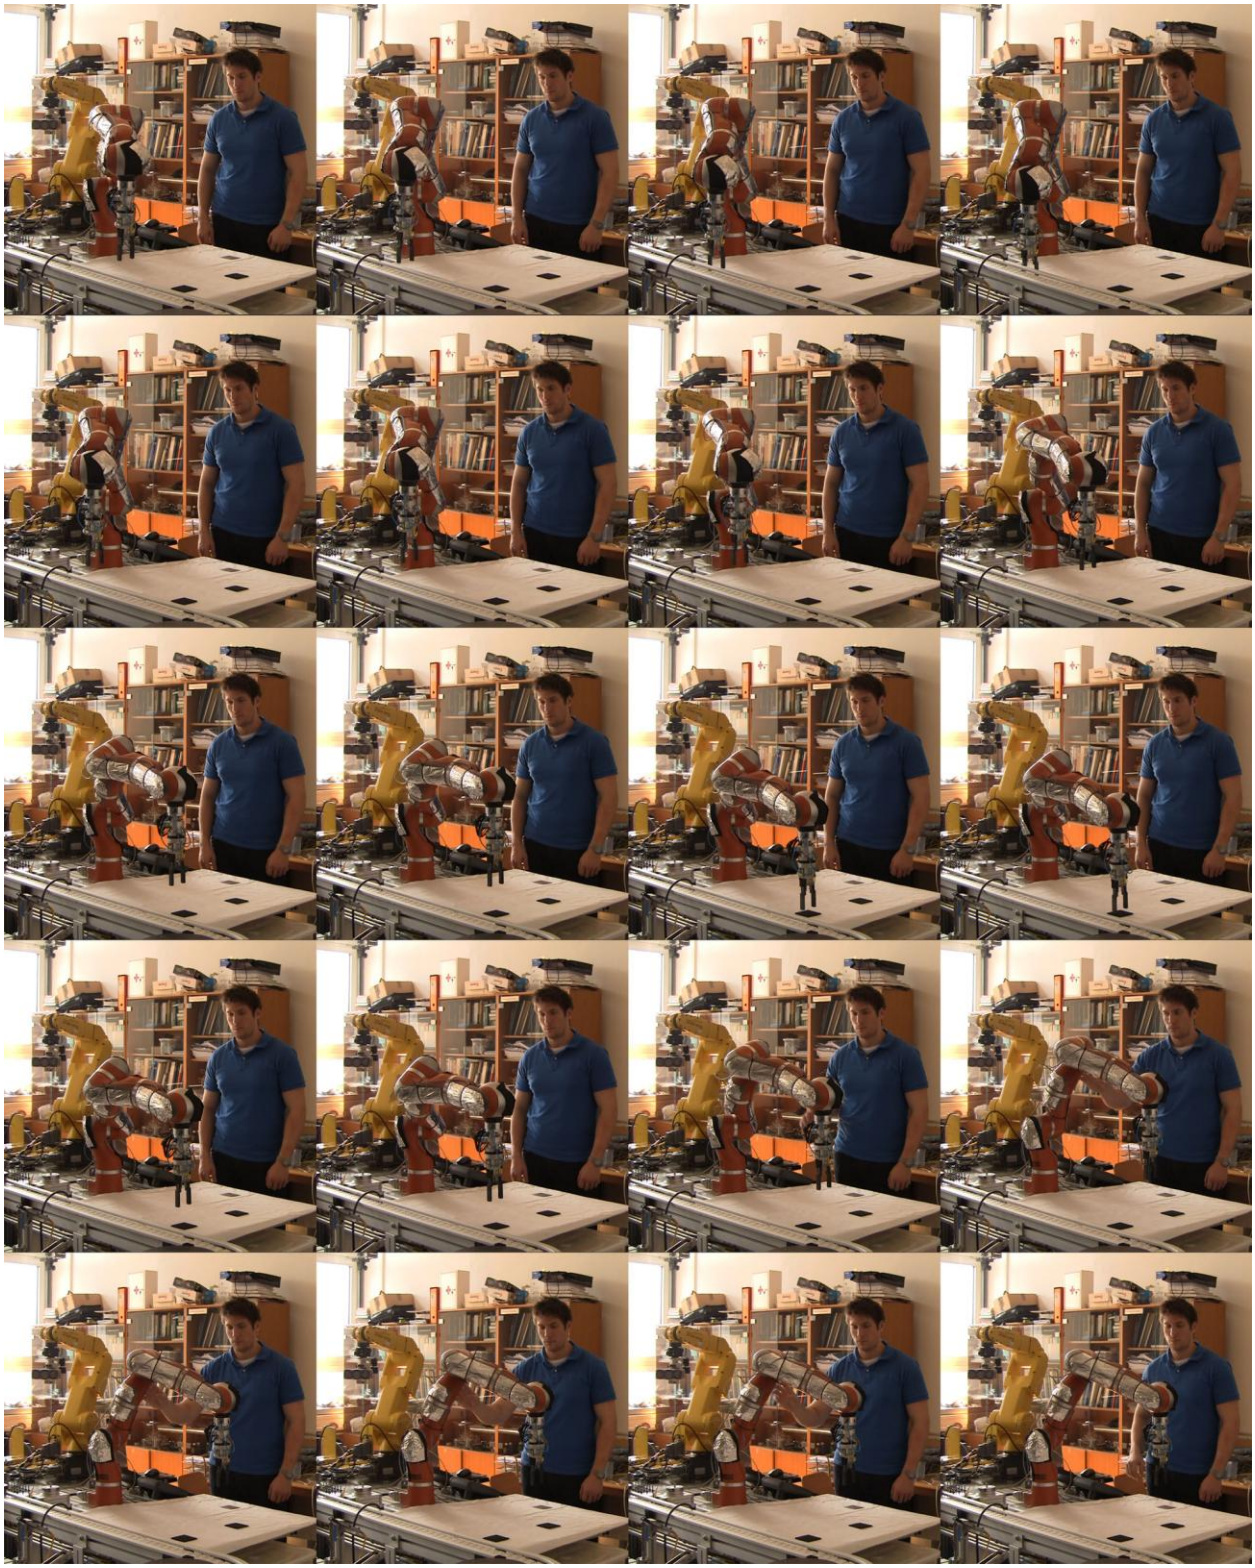

Slika 5.16. *Eksperiment sa zauzetosti radnog prostora.*

Na temelju eksperimenta možemo zaključiti ako je faktor vremenskog otežavanja λ numerički manjeg iznosa tj. ako se pridaje znatno veća važnost posljednjim lancima i udaljenije sekvence se „zaboravljaju", tada će se posljednja sekvenca pokušati replicirati čak i prilikom prilično visoke nesigurnosti da je prostorno izvediva. Primjerice s izrazito visokim faktorom zaboravljanja ($\lambda = 0{,}1$), dovoljna je jako mala vjerojatnost da je cilj dohvatljiv. U suprotnom, ako je ravnomjernije raspoređena važnost, tada je potrebnija mnogo veća sigurnost u dostupnost određenih ciljeva kako bi se replicirala sekvenca koja je vremenski bliže sadašnjem trenutku.

S obzirom na primjenu modela moguće je prilagoditi pragove aktivacije djelovanja kako robot ne bi djelovao u slučaju kada sigurnost nije na zadovoljavajućoj razini. U takvim slučajevima robot čeka intervenciju korisnika ili da se oslobodi radni prostor kako bi mogao djelovati s dovoljnom sigurnošću. Zbog toga je potrebno s obzirom na primjenu odrediti donju granicu vjerojatnosti koja je dovoljna da se izvrši bilo koji zadatak. U suprotnom, sustav ima tendenciju izvođenja djelovanja, čak i s niskom vjerojatnošću u slučaju da ne postoji bolje rješenje, unatoč mogućnosti da je ono pogrešno.

6. Zaključak

Failure is simply the opportunity to begin again, this time more intelligently.

Henry Ford

Rad se nastavlja na istraživanja i razvoj interaktivnih modela u industrijskim i u neurokirurškim primjenama robotike. Osnovna je motivacija razmišljanje da će roboti postati neizostavni sudionici prilikom izvođenja raznih zadataka. Zato se javlja potreba za razvojem novih metoda koje će omogućiti intuitivnu interakciju ljudi i robota u istom radnom prostoru. Glavni cilj istraživanja je razvoj vjerojatnosnog modela pomoću kojeg će robot donositi odluke o svojem djelovanju putem fizičke interakcije s čovjekom. Da bi se taj cilj ostvario, istraživanje je podijeljeno u nekoliko faza. Svaka od njih imala je svoj parcijalni cilj i rezultirala je određenim korakom u stvaranju modela.

U prvom dijelu istraživanja obrađen je problem tumačenja fizičke interakcije čovjeka i robota. Uz razvoj tehnologije taktilni jezik i taktilna interakcija svoju primjenu nalaze i u sučeljima s tehnologijom, pa tako i robotom. Klasifikacijom taktilnih podražaja na temelju kapacitivnog senzora, sile i prostornog položaja razaznaju se elementi interakcije. Uslijed raznovrsnosti i složenosti fizičke interakcije oblikovane su tri glavne kategorije koji sadrže moguće interakcije robota s okolinom i čovjekom. Prva kategorija, opažanje sudara, definira neočekivani kontakt između čovjeka i robota. To znači da se čovjek i robot međusobno ometaju prilikom rada. Taktilnim senzacijama i reaktivnim djelovanjem omogućava se sigurnost čovjeka u takvim slučajevima. Druga kategorija, aktivni kontakt, bavi se očekivanim dodirom čovjeka i robota. Fizički kontakt između čovjeka i robota upotrebljava se kao komunikacijski kanal. Dodirom se obavlja vođenje robota po prostoru i izdavanje raznih naredbi. Treća kategorija, operacije, predstavlja djelovanja robota s ciljem izvršavanja specifičnih dijelova zadataka. Svaka kategorija se s obzirom na svoje specifičnosti dalje dijeli u potkategorije koje podrobnije opisuju interakciju.

Nadalje, kako bi model imao određenu autonomiju i mogućnost kretanja kroz prostor, u sklopu istraživanja obrađen je problem prostornog kretanja. Problem prostornog planiranja vezan je za prostornu mapu i putanje u prostoru. U sklopu istraživanja definirana je višekriterijska interpretacija radnog prostora u kojoj postoji distinkcija između objekata u okolini, čovjeka, ciljeva, samog robota te putanja robota. Robotov radni prostor transformira se u konfiguracijski prostor i dijeli se u polja diskretizirane mreže. Trenutni položaj čovjeka i prepreka smatra se zauzetim dijelom prostora. U višekriterijskoj interpretaciji prostora može se razlikovati sigurnost da je određeno polje zauzeto s obzirom na vjerojatnost. Definirana je i vremenska komponenta, kojom se s prolaskom vremena vrijednosti polja mijenjaju. Robot planira putanju kretanja uzimajući u obzir okupirana polja kako bi se izbjegao sudar robota s čovjekom ili preprekom. Prilikom planiranja robot može razmotriti polja s različitim

vrijednostima vjerojatnosti, od niskih vjerojatnosti do visokih vjerojatnosti zauzetosti za učinkovito planiranje puta. U slučaju planiranja prvo se provjerava je li moguće ostvariti kretanje kroz linearne putanje i putanje koje je prethodno definirao korisnik ili su generirane pretraživanjem. Tek u slučaju da nijedna od njih ne zadovoljava, slijedi pretraživanje prostora stanja kako bi se oblikovala nova putanja. Prostor stanja pretražuje se uz pomoć A* heurističkog algoritma, koji se ponavlja iterativno kroz prostor s preprekama različitog intenziteta tj. vjerojatnosti.

Eksperimentima na realnom sustavu određeni su pragovi sila, brzina i ostalih klasifikacijskih elemenata za različite komponente interakcije. Eksperimentalnim definiranjem parametara klasifikacije brzine pokreta oblikovan je dvokriterijski model klasifikacije na temelju prosječnih i maksimalnih sila. Model je linearno separabilan uz minimalnu pogrešku klasifikacije. Definiranjem parametara klasifikacije smjera pomaka postavljene su tri linearno separabilne klase: vertikalne kretnje, horizontalne kretnje i prostorne kretnje. Definiranjem parametara klasifikacije sile utvrđene su tri različite skupine: bez vanjske sile, mala vanjska sila i velika vanjska sila.

U drugom dijelu istraživanja oblikovan je temeljni model interakcije. Model se oblikuje kao slijed radnji koje robot obavlja, što u konačnici rezultira robotskim djelovanjem. Polazni korak modela je raščlaniti djelovanje na pojedine elemente djelovanja koji tvore stohastički lanac kroz skup stanja. Definiranje varijabli vjerojatnosti lanaca tj. prijelaznih matrica proizlazi iz interakcije s čovjekom. Oblikovanje slijeda obavlja se na temelju demonstracije korisnika. Naučeni obrasci predstavljaju dugoročno znanje na temelju kojeg se oblikuje robotsko djelovanje u skladu s trenutnim stanjem okoline. Vremenskim razlikovanjem bližim se događajima pridaje značajno veći faktor utjecaja, a onim udaljenijim u prošlosti mnogo manji.

U nastavku, eksperimentom simuliranih vrijednosti analizirana je primjenjivost Markovljevih procesa sa svim stanjima i vjerojatnostima prelaska u sljedeće stanje kao elementarnog dijela modela interakcije. Načinjene su usporedbe primjene Markovljevih lanaca prvog reda s lancima višeg reda. Izvršena je analiza udjela uzastopnog ponavljanja elemenata u slučajnim lancima. Na temelju rezultata računske složenosti i postotka iskoristivosti pojedinog reda odabire se stupanj složenosti koji omogućava izvođenje u realnom vremenu uz zadovoljavajući postotak iskoristivosti. Na temelju izmjerenih podataka odabran je Markovljev lanac trećeg reda kao osnova vjerojatnosnog modela.

U trećoj fazi istraživanja razvijena metodologija verificirana je, s ciljem potvrde hipoteze, nizom odabranih problema. U Laboratoriju za projektiranje izradbenih i montažnih sustava

Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu provedeni su pokusi na realnom sustavu koji čine robotska ruka s integriranim senzorima momenata i upravljačkom jedinicom, računalo, kao i „umjetna koža” s mogućnošću razlučivanja ljudskog dodira i neposredne blizine u prvom redu biološkog materijala. Rezultati primjene predloženog tumačenja taktilne interakcije prikazani su u obliku odstupanja klasificiranog podražaja od nametnutog unosa od korisnika. Postupak validacije pokazao je visoku vjerojatnost ispravne klasifikacije, uz određena odstupanja. Određena pojedinačna odstupanja spadaju u rubno područje klasifikacije, gdje postoji mogućnost, iako mala, da se svrstaju u pogrešnu kategoriju. Analizom vrijednosti, s obzirom na visoki postotak uspješno klasificiranih, donosi se zaključak da je metoda klasifikacije pouzdana. Rezultati oblikovanja slijeda djelovanja prikazani su na primjeru izuzimanja i odlaganja predmeta rada. Namjera korisnika je premjestiti predmet s jednog mjesta na drugo u zajedničkom radnom prostoru čovjeka i robota. Prikazani rezultati validacije metode za oblikovanje slijeda djelovanja na primjeru potvrđuju da metoda odgovara namjeni. Eksperimentom su utvrđena ograničenja primjene autonomnog djelovanja. Autonomno djelovanje treba prilagoditi s obzirom na primjenu kako robot ne bi djelovao samostalno u slučaju kada sigurnost nije na zadovoljavajućoj razini. Potrebno je odrediti raspon vjerojatnosti, odnosno određenu razinu povjerenja koja je dovoljna da se obavi djelovanje. U suprotnom, sustav ima tendenciju izvođenja djelovanja unatoč mogućnosti da je ono pogrešno.

6.1. Znanstveni doprinos rada

Na temelju istraživanja može se reći da je inicijalna hipoteza o mogućnosti oblikovanja funkcije robotskog djelovanja u interakciji s čovjekom potvrđena. Interpretacijom fizičke interakcije pomoću vjerojatnosnog modela koji se zasniva na višekriterijskoj definiciji radnog prostora, stohastičkom lancu stanja i pamćenju iskustvenog znanja s vremenskim razlikovanjem događaja postignuto je očekivano ponašanje robota u ljudskoj okolini.

Najvažniji doprinosi rada su:

- Doprinos tumačenju i implementaciji fizičke interakcije između čovjeka i robota, čime se osigurava intuitivan prijenos informacija (namjera, instrukcija) od čovjeka.
- Oblikovanje višekriterijske interpretacije radnog prostora, koja služi kao osnova prostornog planiranja.
- Novi vjerojatnosni model fizičke interakcije koji oblikuje funkciju robotskog djelovanja.

6.2. Smjerovi daljnjeg istraživanja

Na razini zapisa stanja prostora i planiranja kretanja moguće je proširenje s dvodimenzionalnog simplificiranog prostora na potpuni trodimenzionalni prostor. Takvo proširenje iziskuje i proširenje dimenzija konfiguracijskog prostora, koje tada postaju jednake broju stupnjeva slobode kretanja, što odgovara broju zglobova robota $n = 7$, $C \subset \mathbb{R}^7$. Proširenjem na trodimenzionalni prostor dobila bi se vjernija slika prostora i mogućnost zaobilaženja prepreka s obzirom na pripadajuću visinu.

Vjerojatnosni model interakcije kojim se oblikuje slijed djelovanja je proširiv na više oblika percepcije. Model nije oblikovan u smislu da se odvoji od ostalih oblika komunikacije, jednostavno zato što se ljudi koriste svim svojim osjetilima prilikom suradnje. Kratkoročno je moguće ostvariti određene zadatke pomoću izolirane upotrebe pojedinog osjetila, bilo da je to vid, sluh ili dodir. Očekuju se nešto bolji rezultati integracijom raznih kombinacija dvaju ili triju osjetila, no cjelovito rješenje je potpuna integracija svih vrsta osjetila. Uslijed složenosti različitih vrsta osjetila i povećanja kompleksnosti modela uslijed integracije više vrsta osjetila implementacija takvog modela je u dugoročnoj perspektivi.

Konačno, perspektiva istraživanja je primjena modela taktilne interakcije u stvarnim okruženjima. Kroz istraživanje će se odrediti prikladnost metodologije u raznim domenama, počevši od laboratorijskih uvjeta kroz industrijske primjene pa sve do vrlo složene primjene u medicini. Stupanj kompleksnosti problema interakcije otvara čitav niz pitanja te će sigurno biti predmet istraživanja dugi niz godina.

7. Literatura

[1] Norman D.A. The design of everyday things. New York: Basic Books, 2002.

[2] Brynjolfsson E.; Mc*Afee A. Race Against the Machine.* Lexington: Digital Frontier Press, 2012.

[3] Neumeier M. Metaskills: Five Talents for the Robotic Age. New York: Pearson Education, 2012.

[4] Stilwell J.M.; Cermak S.A. Perceptual functions of the hand.// Hand function in the child (1995), str. 55–92.

[5] Goldstein E. Sensation and Perception. 9. izd. Belmont: Cengage Learning, 2013.

[6] Gains N. Brand EsSense: Using Sense, Symbol and Story to Design Brand Identity. Philadelphia: Kogan Page Publishers, 2013.

[7] Squire L.R. Fundamental neuroscience. 3. izd. Boston: Elsevier / Academic Press, 2008.

[8] Haans A.; IJsselsteijn W. Mediated social touch: a review of current research and future directions//Virtual Reality, 9, 2–3(2005), str. 149–159.

[9] Gallace A.; Spence C. The science of interpersonal touch: An overview//Neuroscience & Biobehavioral Reviews, 34, 2(2010), str. 246–259.

[10] Percepcija – doživljaj svijeta oko sebe | Istraži Me. [Citirano: 24.02.2014] Dostupno na: http://www.istrazime.com/razvojna-psihologija/percepcija-kako-dozivljavamo-svijet-oko-sebe/#.

[11] Taktilni HZJ - Dodir. [Citirano: 07.02.2015] Dostupno na: http://www.dodir.hr/thzj.php#.

[12] Communicating with customers who are disabled - A guide for telecoms companies, 10 September 2001. [Citirano: 10.03.2015] Dostupno na: http://www.ofcom.org.uk/static/archive/oftel/publications/consumer/gpm0901.htm.

[13] Kern T.A., Ed. Engineering Haptic Devices. Heidelberg: Springer, 2009.

[14] Anić V. Rječnik hrvatskoga jezika. 4. izd. Zagreb: Novi Liber, 2004.

[15] Breazeal C.; Gray J.; Hoffman G.; Berlin M. Social robots: Beyond tools to partners. // Robot and Human Interactive Communication, 2004. ROMAN 2004. 13th IEEE International Workshop on, 2004, str. 551–556.

[16] Siciliano B.; Khatib O. Springer Handbook of Robotics. Heidelberg: Springer, 2008.

[17] Chen F.; Sekiyama K.; Sasaki H.; Huang J.; Sun B.; Fukuda T. Assembly strategy modeling and selection for human and robot coordinated cell assembly. // Intelligent Robots and Systems (IROS), 2011 IEEE/RSJ International Conference on, 2011, str. 4670–4675.

[18] Duan F.; Tan J.T.C.; Arai T. A new human-robot collaboration assembly system for cellular manufacturing. // Control Conference (CCC), 2011 30th Chinese, 2011, str. 5468–5473.

[19] Kato R.; Fujita M.; Arai T. Development of advanced cellular manufacturing system with human-robot collaboration. // RO-MAN, 2010 IEEE, 2010, str. 355–360.

[20] Lenz C.; Nair S.; Rickert M.; Knoll A.; Rosel W.; Gast J.; Bannat A.; Wallhoff F. Joint-action for humans and industrial robots for assembly tasks. // Robot and Human Interactive Communication, 2008. RO-MAN 2008. The 17th IEEE International Symposium on, 2008, str. 130–135.

[21] Radi M.; Reinhart G. Industrial Haptic Robot Guidance System for Assembly Processes. // Haptic Audio visual Environments and Games, 2009. HAVE 2009. IEEE International Workshop on, 2009, str. 69–74.

[22] Mortl A.; Lawitzky M.; Kucukyilmaz A.; Sezgin M.; Basdogan C.; Hirche S. The role of roles: Physical cooperation between humans and robots. //The International Journal of Robotics Research, 31, 13(2012), str. 1656–1674.

[23] Miyashita T.; Tajika T.; Ishiguro H.; Kogure K.; Hagita N. Haptic communication between humans and robots. // Robotics Research, Springer, 2007, str. 525–536.

[24] Suwanratchatamanee K.; Matsumoto M.; Hashimoto S. Human-machine interaction through object using robot arm with tactile sensors. // Robot and Human Interactive Communication, 2008. RO-MAN 2008. The 17th IEEE International Symposium on, 2008, str. 683–688.

[25] Hanyu R.; Tsuji T.; Abe S. Command recognition based on haptic information for a robot arm. // Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on, 2010, str. 4662–4667.

[26] Steinbach E.; Hirche S.; Ernst M.; Brandi F.; Chaudhari R.; Kammerl J.; Vittorias I. Haptic Communications. //Proceedings of the IEEE, 100, 4(2012), str. 937–956.

[27] Petrovskaya A.; Khatib O. Global Localization of Objects via Touch. //IEEE Transactions on Robotics, 27, 3(2011), str. 569–585.

[28] Fulkar V.N.; Shivramwar M.V.; Alkari A.A. Applications of haptics technology in advance robotics. // Emerging Trends in Robotics and Communication Technologies (INTERACT), 2010 International Conference on, 2010, str. 273–277.

[29] Jain A.; Killpack M.D.; Edsinger A.; Kemp C.C. Reaching in clutter with whole-arm tactile sensing. //The International Journal of Robotics Research, 32, 4(2013), str. 458–482.

[30] Bhattacharjee T.; Rehg J.M.; Kemp C.C. Haptic classification and recognition of objects using a tactile sensing forearm. // Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on, 2012, str. 4090–4097.

[31] Voyles Jr R.M.; Khosla P.K. Tactile gestures for human/robot interaction. // Intelligent Robots and Systems 95.'Human Robot Interaction and Cooperative Robots', Proceedings. 1995 IEEE/RSJ International Conference on, 1995, 3, str. 7–13.

[32] Grunwald G.; Schreiber G.; Albu-Schaffer A.; Hirzinger G. Programming by touch: the different way of human-robot interaction. //IEEE Transactions on Industrial Electronics, 50, 4(2003), str. 659–666.

[33] Colomé A.; Pardo D.; Alenya G.; Torras C. External force estimation during compliant robot manipulation. // Robotics and Automation (ICRA), 2013 IEEE International Conference on, 2013, str. 3535–3540.

[34] Schreiber G.; Stemmer A.; Bischoff R. The fast research interface for the kuka lightweight robot. // IEEE Workshop on Innovative Robot Control Architectures for Demanding (Research) Applications How to Modify and Enhance Commercial Controllers (ICRA 2010), 2010.

[35] Frigola M.; Casals A.; Amat J. Human-robot interaction based on a sensitive bumper skin. // Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on, 2006, str. 283–287.

[36] Minato T.; Yoshikawa Y.; Noda T.; Ikemoto S.; Ishiguro H.; Asada M. CB2: A child robot with biomimetic body for cognitive developmental robotics. // Humanoid Robots, 2007 7th IEEE-RAS International Conference on, 2007, str. 557–562.

[37] Stiehl W.D.; Breazeal C.; Han K.; Lieberman J.; Lalla L.; Maymin A.; Salinas J.; Toscano R.; Tong C.H.; Kishore A.; Berlin M.; Gray J. The design of the huggable: a therapeutic robotic companion for relational, affective touch. // Proceedings of the AAAI Fall Symposium on Caring Machines: AI in Eldercare, 2006.

[38] Chang W.-L.; Šabanovic S.; Huber L. Use of seal-like robot PARO in sensory group therapy for older adults with dementia. // Proceedings of the 8th ACM/IEEE international conference on Human-robot interaction, 2013, str. 101–102.

[39] Robins B.; Amirabdollahian F.; Dautenhahn K. Investigating Child-Robot Tactile Interactions: A Taxonomical Classification of Tactile Behaviour of Children with Autism Towards a Humanoid Robot. // ACHI 2013, The Sixth International Conference on Advances in Computer-Human Interactions, 2013, str. 89–94.

[40] Yohanan S.; MacLean K.E. A tool to study affective touch. // CHI'09 Extended Abstracts on Human Factors in Computing Systems, 2009, str. 4153–4158.

[41] Sabanovic S.; Bennett C.C.; Chang W.-L.; Huber L. PARO robot affects diverse interaction modalities in group sensory therapy for older adults with dementia. // Rehabilitation Robotics (ICORR), 2013 IEEE International Conference on, 2013, str. 1–6.

[42] Yohanan S.; MacLean K.E. The Role of Affective Touch in Human-Robot Interaction: Human Intent and Expectations in Touching the Haptic Creature. //International Journal of Social Robotics, 4, 2(2011), str. 163–180.

[43] Argall B.D.; Billard A.G. A survey of Tactile Human–Robot Interactions. //Robotics and Autonomous Systems, 58, 10(2010), str. 1159–1176.

[44] Kheddar A.; Billard A. A tactile matrix for whole-body humanoid haptic sensing and safe interaction, // Robotics and Biomimetics (ROBIO), 2011 IEEE International Conference on, 2011, str. 1433–1438.

[45] Navarro S.E.; Marufo M.; Ding Y.; Puls S.; Goger D.; Hein B.; Worn H. Methods for safe human-robot-interaction using capacitive tactile proximity sensors. // Intelligent Robots and Systems (IROS), 2013 IEEE/RSJ International Conference on, 2013, str. 1149–1154.

[46] Argall B.D.; Sauser E.L.; Billard A.G. Tactile guidance for policy refinement and reuse. // Development and Learning (ICDL), 2010 IEEE 9th International Conference on, 2010, str. 7–12.

[47] Medina J.R.; Shelley M.; Lee D.; Takano W.; Hirche S. Towards interactive physical robotic assistance: Parameterizing motion primitives through natural language. // RO-MAN, 2012 IEEE, 2012, str. 1097–1102.

[48] Lawitzky M.; Medina J.R.; Lee D.; Hirche S. Feedback motion planning and learning from demonstration in physical robotic assistance: differences and synergies. //

Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on, 2012, str. 3646–3652.

[49] Schmid A.J.; Hoffmann M.; Wörn H. A tactile language for intuitive human-robot communication. // Proceedings of the 9th international conference on Multimodal interfaces, 2007, str. 58–65.

[50] Khambadkar V.; Folmer E. A tactile-proprioceptive communication aid for users who are deafblind. // Haptics Symposium (HAPTICS), 2014 IEEE, 2014, str. 239–245.

[51] Staub C.; Can S.; Knoll A.; Nitsch V.; Karl I.; Farber B. Implementation and evaluation of a gesture-based input method in robotic surgery. // Haptic Audio Visual Environments and Games (HAVE), 2011 IEEE International Workshop on, 2011, str. 1–7.

[52] Lee D.; Ott C. Incremental motion primitive learning by physical coaching using impedance control. // Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on, 2010, str. 4133–4140.

[53] Tovar-Arriaga S.; Vargas J.E.; Ramos J.M.; Aceves M.A.; Gorrostieta E.; Kalender W.A. A Fully Sensorized Cooperative Robotic System for Surgical Interventions. //Sensors, 12, 12(2012), str. 9423–9447.

[54] Staub C.; Can S.; Jensen B.; Knoll A.; Kohlbecher S. Human-computer interfaces for interaction with surgical tools in robotic surgery. // Biomedical Robotics and Biomechatronics (BioRob), 2012 4th IEEE RAS & EMBS International Conference on, 2012, str. 81–86.

[55] Rosen J.; Hannaford B.; Satava R.M. Surgical Robotics. Boston, MA: Springer US, 2011.

[56] Ferreira J.F.; Miranda Dias J. Probabilistic Approaches to Robotic Perception. Cham: Springer International Publishing, 2014.

[57] Thrun S.; Burgard W.; Fox D. Probabilistic robotics. Cambridge: MIT press, 2005.

[58] Schrempf O.C.; Hanebeck U.D.; Schmid A.J.; Worn H. A novel approach to proactive human-robot cooperation. // Robot and Human Interactive Communication, 2005. ROMAN 2005. IEEE International Workshop on, 2005, str. 555–560.

[59] Glasauer S.; Huber M.; Basili P.; Knoll A.; Brandt T. Interacting in time and space: Investigating human-human and human-robot joint action. // RO-MAN, 2010 IEEE, 2010, str. 252–257.

[60] Awais M.; Henrich D. Human-robot collaboration by intention recognition using probabilistic state machines. // Robotics in Alpe-Adria-Danube Region (RAAD), 2010 IEEE 19th International Workshop on, 2010, str. 75–80.

[61] Vidal E.; Thollard F.; De La Higuera C.; Casacuberta F.; Carrasco R.C. Probabilistic finite-state machines-part I. //Pattern Analysis and Machine Intelligence, IEEE Transactions on, 27, 7(2005), str. 1013–1025.

[62] Vidal E.; Thollard F.; De La Higuera C.; Casacuberta F.; Carrasco R.C. Probabilistic finite-state machines-part II. //Pattern Analysis and Machine Intelligence, IEEE Transactions on, 27, 7(2005), str. 1026–1039.

[63] Kartoun U.; Stern H.; Edan Y. A Human-Robot Collaborative Reinforcement Learning Algorithm. //Journal of Intelligent & Robotic Systems, 60, 2(2010), str. 217–239.

[64] Thomaz A.L.; Breazeal C. Teachable robots: Understanding human teaching behavior to build more effective robot learners. //Artificial Intelligence, 172, 6–7(2008), str. 716–737.

[65] Stulp F.; Theodorou E.A.; Schaal S. Reinforcement Learning With Sequences of Motion Primitives for Robust Manipulation. //IEEE Transactions on Robotics, 28, 6(2012), str. 1360–1370.

[66] Dindo H.; Schillaci G. An adaptive probabilistic graphical model for representing skills in pbd settings. // Proceedings of the 5th ACM/IEEE international conference on Human-robot interaction, 2010, str. 89–90.

[67] Melchior N.A.; Simmons R. Graph-based trajectory planning through programming by demonstration. // Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on, 2012, str. 1929–1936.

[68] Flacco F.; Kroger T.; De Luca A.; Khatib O. A depth space approach to human-robot collision avoidance. // Robotics and Automation (ICRA), 2012 IEEE International Conference on, 2012, str. 338–345.

[69] Iehl R.; Cortés J.; Siméon T. Costmap planning in high dimensional configuration spaces. // Advanced Intelligent Mechatronics (AIM), 2012 IEEE/ASME International Conference on, 2012, str. 166–172.

[70] Jaillet L.; Cortés J.; Siméon T. Sampling-based path planning on configuration-space costmaps. //Robotics, IEEE Transactions on, 26, 4(2010), str. 635–646.

[71] Mainprice J.; Berenson D. Human-robot collaborative manipulation planning using early prediction of human motion. // Intelligent Robots and Systems (IROS), 2013 IEEE/RSJ International Conference on, 2013, str. 299–306.

[72] Ding H. Control of robotic systems for safe interaction with human operators. // IJCAI Proceedings-International Joint Conference on Artificial Intelligence, 2011, 22, str. 2792.

[73] Russell S.J.; Norvig P.; Davis E. Artificial intelligence: a modern approach. Upper Saddle River, NJ: Prentice Hall, 2010.

[74] Scriven M. An essential unpredictability in human behavior. // Scientific Psychology : Principles and Approaches, 1964.

[75] Baxter L.K.; IEEE Industrial Electronics Society Capacitive sensors design and applications. New York: IEEE Press, 1997.

[76] Drobilo L. Unaprijeđivanje apsolutne točnosti robotske ruke, diplomski rad, 2012

[77] Bischoff R.; Kurth J.; Schreiber G.; Koeppe R.; Albu-Schäffer A.; Beyer A.; Eiberger O.; Haddadin S.; Stemmer A.; Grunwald G. The KUKA-DLR Lightweight Robot arm-a new reference platform for robotics research and manufacturing. // Robotics (ISR), 2010 41st international symposium on and 2010 6th German conference on robotics (ROBOTIK), 2010, str. 1–8.

[78] Albu-Schaffer A.; Eiberger O.; Grebenstein M.; Haddadin S.; Ott C.; Wimbock T.; Wolf S.; Hirzinger G. Soft robotics. //IEEE Robotics & Automation Magazine, 15, 3(2008), str. 20–30.

[79] Kazemi M.; Valois J.-S.; Bagnell J.A.; Pollard N. Robust object grasping using force compliant motion primitives. // Robotics: Science and Systems (2012).

[80] Likar N.; Žlajpah L. External Joint Torque-based Estimation of Contact Information. //International Journal of Advanced Robotic Systems(2014), str. 1.

[81] Eysenck M.W.; Keane M.T. Cognitive psychology: a student's handbook, 6. izd. New York: Psychology Press, 2010.

[82] Choset H.M. Principles of Robot Motion: Theory, Algorithms, and Implementation. London : MIT Press, 2005.

[83] Elezović N. Vjerojatnost i statistika - Slučajne varijable. Zagreb: Element, 2010.

[84] Nastavni materijali kolegija inženjerska matematika II, Doc. dr. sc. Nelida Črnjarić - Žic, Tehnički Fakultet, Sveučilište u Rijeci

[85] Markovljev lanac - Wikipedija. [Citirano: 10.3.15] Dostupno na: http://hr.wikipedia.org/wiki/Markovljev_lanac.

[86] Gibilisco S. Concise Encyclopedia of Robotics. New York: McGraw-Hill Education, 2002.

[87] Carter R.; Aldridge S.; Page M.; Parker S.; Frith C.D.; Frith U.; Shulman M.B. The human brain book. New York, N.Y.: DK Pub., 2009.

[88] Berntson G.G.; Cacioppo J.T. Handbook of Neuroscience for the Behavioral Sciences. Hoboken: Wiley, 2009.

[89] Sutton R.S.; Barto A.G. Reinforcement Learning: An Introduction. Chester: Bradford Book, 1998.

[90] Mitchell T.M. Machine Learning. New York: McGraw-Hill, 1997.

[91] Benšić M.; Šuvak N. Uvod u vjerojatnost i statistiku. Osijek: Grafika d.o.o., 2014.

Životopis

Bojan Šekoranja rođen je 16. veljače 1986. godine u Zagrebu. Po završetku XV. prirodoslovno-matematičke gimnazije 2004. upisuje Fakultet strojarstva i brodogradnje (FSB) Sveučilišta u Zagrebu. Diplomirao je u listopadu 2009., obranivši diplomski rad s temom „Primjena pokretnog vizijskog sustava u robotskoj montaži", pod mentorstvom profesora Bojana Jerbića. Za uspjeh na studiju nagrađen je medaljom Fakulteta strojarstva i brodogradnje za najbolje studente. Po završetku diplomskog studija upisuje poslijediplomski studij smjera Robotika i automatizacija, a od veljače 2010. godine radi kao asistent i znanstveni novak pri Zavodu za robotiku i automatizaciju proizvodnih sustava na Katedri za projektiranje izradbenih i montažnih sustava Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. Aktivno je sudjelovao u znanstvenim projektima: „IGRAMO –Improving grasping methods based on observations", „ACRON – A new concept of Applied Cognitive Robotics in clinical Neuroscience", znanstvenom projektu MZOS-a „Autonomna višeagentska automatska montaža", te tehnologijskim projektima: „Automatska montaža dvoručnim robotom" i „Primjena robota u neurokirurgiji – RONNA" te strukturnom projektu „RONNA – Robotska neuronavigacija". Dosad je kao autor ili koautor objavio više znanstvenih radova: izvorni znanstveni i pregledni radovi u CC časopisima (1), znanstveni radovi u drugim časopisima (1), znanstveni radovi u zbornicima skupova s međunar. rec. (12).

Biography

Bojan Šekoranja was born on February 16, 1986 in Zagreb. He graduated “XV gimnazija” high school in 2004 and enrolled the Faculty of Mechanical Engineering and Naval Architecture (FSB) at the University of Zagreb. He obtained his degree in October 2009, after successfully defending his thesis “Vision system application in robotic assembly” under the supervision of professor Bojan Jerbić. He was awarded the "Medal of the Faculty of Mechanical Engineering and Naval Architecture" in 2009 for best students. After graduation he enrolled the postgraduate program of Robotics and automation and from February 2010 he works as a research and teaching assistant at the Department of Robotics and Production System Automation, Chair for Manufacturing and Assembly System Planning, at FSB. He actively participated in research projects: „IGRAMO – Improving grasping methods based on observations“, „ACRON - A new concept of Applied Cognitive RObotics in clinical Neuroscience“, „Autonomous multiagent automatic assembly“, technological projects: „Automatic dual-arm robotic assembly“, „Application of robots in neurosurgery“ and structural funds project „RONNA – robotic neuronavigation“. He published several papers as an author and co-author: CC scientific journal papers (1), other journal papers (1) and scientific conference papers (12)

Popis radova

Izvorni znanstveni i pregledni radovi u CC časopisima:

1. Jerbić, B.; Nikolić, G.; Chudy, D.; Švaco, M.; Šekoranja, B. Robotic application in neurosurgery using intelligent visual and haptic interaction, International Journal of Simulation Modelling, vol. 14, no. 1, p. 71–84, 2015.

Znanstveni radovi u drugim časopisima:

1. Šekoranja, B.; Jerbić, B.; Šuligoj, F. Virtual surface for human-robot interaction, Transactions of FAMENA, vol. 39, no. 1, p. 53-64, 2015

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom:

1. Švaco, M.; Šekoranja, Bojan; Šuligoj, F.; Jerbić, B. Calibration of an Industrial Robot Using a Stereo Vision System // Procedia Engineering 69 / Branko Katalinić (ur.). 2014. 459-463 (poster,međunarodna recenzija,objavljeni rad,znanstveni).
2. Šekoranja, B.; Bašić, D.; Švaco, M.; Šuligoj, F.; Jerbić, B. Human-Robot Interaction Based on Use of Capacitive Sensors // Procedia Engineering 69 / Branko Katalinic (ur.). 2014. 464-468 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
3. Šuligoj, F.; Šekoranja, B.; Švaco, M.; Jerbić, B. Object Tracking with a Multiagent Robot System and a Stereo Vision Camera // Procedia Engineering. 2014. 968-973 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
4. Švaco, M.; Bašić, D.; Šekoranja, B.; Jerbić, B. A capacitive sensor for human-robot interaction // Annals of DAAAM for 2012. & Proceedings of the 23rd International DAAAM Symposium / Katalinić, Branko (ur.). Vienna : DAAAM International, 2012. 819-822 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
5. Švaco, M.; Šekoranja B.; Jerbić B. Industrial Robotic System with Adaptive Control // Procedia Computer Science 12 / Cihan H. Dagli (ur.). 2012. 164-169 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

6. Švaco, M.; Šekoranja, B.; Jerbić, B. A multiagent framework for industrial robotic applications // Procedia Computer Science 6 / Cihan H. Dagli (ur.). 2011. 291-296 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
7. Švaco, M.; Šekoranja, B.; Jerbić, B. Autonomous Planning Framework for Distributed Multiagent Robotic Systems // Technologica Innovation for Sustainability / Camarinha-Matos, Luis M (ur.). Heidelberg : Springer Verlag, 2011. 147-154 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
8. Švaco, M.; Šekoranja, B.; Jerbić, B. Cooperative Robotic Assembly System // 2011 IEEE International Conference on Intelligent Computing and Intelligent Systems (ICIS 2011) / Chen, Wen ; Li, Shaozi (ur.). Institute of Electrical and Electronics Engineers (IEEE), 2011. (poster,međunarodna recenzija,objavljeni rad,znanstveni).
9. Švaco, M.; Šekoranja, B.; Jerbić, B. Multiagent Robotic Collaborative Framework // Annals of DAAAM for 2011 & Proceedings of the 22nd International DAAAM Symposium / Katalinić, Branko (ur.). Vienna : DAAAM Iternational, 2011. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).
10. Švaco, M.; Šekoranja B.; Jerbić B. Service Oriented Robotic Assembly Architecture // Proceedings of 13th International Scientific Conference on Production Engineering / Abele E., Udiljak T., Ciglar D. (ur.). Zagreb : Hrvatska udruga proizvodnog strojarstva, 2011. (međunarodna recenzija,objavljeni rad,znanstveni).
11. Švaco, M.; Šekoranja, B.; Jerbić, B. A Multiagent Approach for Development of a Flexible and Adaptive Robotic Assembly Work Cell // The 3rd International Conference on Computational Intelligence and Industrial Application (PACIIA 2010) : proceedings / Zhang, Yanduo ; Tan, Honghua (ur.). Institute of Electrical and Electronics Engineers, Inc., 2010. 64-67 (poster,međunarodna recenzija,objavljeni rad,znanstveni).
12. Švaco, M.; Šekoranja, B.; Jerbić, B. Heuristic Action Planning Algorithm for Distributed Multiagent Systems // Annals of DAAAM for 2010 & Proceedings of the 21st International DAAAM Symposium / Katalinić, Branko (ur.). Vienna : DAAAM Iternational, 2010. 1067-1069 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).