



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Tomislav Stipančić, dipl.ing.

**SPOZNAJNI MODEL UPRAVLJANJA
GRUPOM INDUSTRIJSKIH ROBOTA**

DOKTORSKI RAD

Zagreb, 2013.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Tomislav Stipančić, dipl. ing.

COGNITIVE MODEL FOR THE CONTROL OF A GROUP OF INDUSTRIAL ROBOTS

DOCTORAL THESIS

Zagreb, 2013.



Sveučilište u Zagrebu
FAKULTET STROJARSTVA I BRODOGRADNJE

Tomislav Stipančić, dipl. ing.

SPOZNAJNI MODEL UPRAVLJANJA GRUPOM INDUSTRIJSKIH ROBOTA

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Bojan Jerbić

Zagreb, 2013.



University of Zagreb
FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Tomislav Stipančić, dipl. ing.

COGNITIVE MODEL FOR THE CONTROL OF A GROUP OF INDUSTRIAL ROBOTS

DOCTORAL THESIS

Supervisor:
Prof. dr. sc. Bojan Jerbić

Zagreb, 2013.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:	004.89:681.51
Ključne riječi:	sveprisutno računarstvo, kontekstualna spoznaja, semantika, probabilistička robotika.
Znanstveno područje:	Tehničke znanosti.
Znanstveno polje:	Strojarstvo.
Institucija u kojoj je rad izrađen:	Fakultet strojarstva i brodogradnje, Zagreb.
Mentor rada:	dr. sc. Bojan Jerbić, red. prof.
Broj stranica:	171
Broj slika:	97
Broj tablica:	57
Broj korištenih bibliografskih jedinica:	109
Datum obrane:	29.05.2013.
Povjerenstvo:	dr. sc. Mladen Crneković, red. prof. – predsjednik, dr. sc. Bojan Jerbić, red. prof. – voditelj, dr. sc. Zdenko Kovačić, red. prof. – član povjerenstva
Institucija u kojoj je rad pohranjen:	Fakultet strojarstva i brodogradnje, Zagreb

“ Čovjek samo srcem dobro vidi. Bitno je očima nevidljivo. ”
Antoine de Saint – Exupéry, Mali princ

Na prvome mjestu, iskoristit ću priliku da se zahvalim svojem mentoru, prof. dr. sc. Bojanu Jerbiću što mi je omogućio dolazak na Fakultet, te što mi je pružio nesebičnu podršku kako u znanstvenom tako i u prijateljskom smislu. Hvala na svim raspravama, savjetima te podijeljenim iskustvima koja su me učila životu.

Također, zahvaljujem se svojoj supruzi Moniki koja mi je pružila razumijevanje i podršku kada mi je najviše trebala. Stoga ovaj rad posvećujem Tebi i Petri.

Zahvaljujem se svojim roditeljima i bratu što su me naučili primjerom što znači ljubav.

Od svega srca se zahvaljujem svojem prijatelju i kolegi, dr. sc. Petru Ćurkoviću koji mi je svojim primjerom, konkretnim savjetima te filozofskim raspravama pomogao da ovaj put do disertacije bude što lakši.

Prof. dr. sc. Božo Vranješ mi je, prije svega ljudskim odnosom i savjetima pomagao kada god bih naišao na nedoumice i probleme.

Zahvaljujem se članovima komisije, prof. dr. sc. Zdenku Kovačiću, te prof. dr. sc. Mladenu Crnekoviću koji su me uz mojeg mentora, kvalitetno savjetovali tijekom izrade disertacije.

Prof. dr. sc. Zoran Kunica mi je također, bezrezervno pomagao savjetima kada god je bilo potrebno.

Zahvaljujem se svojim prijateljima s Katedre, Petru, Denisu, Marku, Bojanu i Filipu koji su ponekad podijelili križ vođenja nastave i ostalih obaveza kako bih mogao raditi na disertaciji.

Zahvaljujem se svoj svojoj dragoj rodbini i prijateljima na žrtvi koju su morali podnijeti za vrijeme dok sam bio fizički, odnosno psihički nedostupan.

Za Petru i Moniku

“ *Only a life lived for others is a life worthwhile.* ”

Albert Einstein

“ *To live a creative life, we must lose our fear
of being wrong.* ”

Joseph Chilton Pearce.

PODACI ZA BIBLIOGRAFSKU KARTICU	VII
ZAHVALA	VII
SADRŽAJ.....	VII
POPIS SLIKA.....	IX
POPIS TABLICA	XII
POPIS VAŽNIJIH OZNAKA I KRATICA.....	XIV
SAŽETAK.....	XVII
SUMMARY.....	XVIII
1. UVOD.....	1
2. SVEPRISUTNO RAČUNARSTVO.....	13
3. PRIKAZ ZNANJA ZASNOVAN NA ONTOLOGIJAMA.....	17
3.1. VIZIJA SEMANTIČKOG WEB-A	17
3.2. ONTOLOGIJE	22
3.3. ZAKLJUČIVANJE ZASNOVANO NA DESKRIPTIVNOJ LOGICI	27
3.4. OWL – ONTOLOŠKI JEZIK ZA PRIMJENU NA WEBU	29
4. ROBOTIKA ZASNOVANA NA PROBABILISTIČKIM METODAMA	32
4.1. PROBABILISTIKA KAO DIO UMJETNE INTELIGENCIJE	32
4.2. TEORIJSKE OSNOVE	34
4.3. BAYESOVE MREŽE	37
4.3.1. ČVOROV I VRIJEDNOSTI	42
4.3.2. STRUKTURA BAYESOVE MREŽE.....	43
4.3.3. PARAMETRIZACIJA NEOVISNIH VARIJABLI	44
5. SPOZNAJNI MODEL UPRAVLJANJA GRUPOM INDUSTRIJSKIH ROBOTA	46
5.1. AGENTI, VIŠEAGENTSKI SUSTAVI.....	46
5.2. SPOZNAJNI MODEL	48
5.3. OKOLINA.....	50
5.4. PREDLOŽENA ARHITEKTURA SUSTAVA	50

5.5.	IMPLEMENTACIJA SPOZNAJNOG MODELA U STVARNU OKOLINU	52
5.6.	ONTOLOŠKA JEZGRA MODELA	57
5.7.	ZAKLJUČIVANJE TEMELJENO NA BAYESOVOJ MREŽI	73
5.7.1.	TOPOLOGIJA BAYESOVE MREŽE	75
5.7.2.	IZRAČUN TABLICA UVJETNIH VJEROJATNOSTI.....	80
5.7.3.	POSTAVLJANJE UPITA BAYESOVOJ MREŽI	81
5.7.4.	PRIMJERI SCENARIJA	82
5.7.5.	RAZVOJ MREŽE I PODEŠAVANJE PARAMETARA	83
6.	VALIDACIJA I VERIFIKACIJA PREDLOŽENE METODOLOGIJE.....	94
6.1.	DRUGI SCENARIJ	94
6.2.	TREĆI SCENARIJ	104
6.3.	VALIDACIJA METODOLOGIJE ANALIZOM UTJECAJA ČVOROVA MREŽE.....	114
7.	ZAKLJUČAK	121
8.	LITERATURA.....	125
	PRILOG A. – OWL PROGRAMSKI KOD	131
	PRILOG B. IZRAČUN TEŽINSKIH FAKTORA VARIJABLI.....	138
	PRILOG C. IZRAČUN VRIJEDNOSTI UVJETNIH VJEROJATNOSTI	140
	PRILOG D. KORIGIRANE VRIJEDNOSTI UVJETNIH VJEROJATNOSTI	164
	ŽIVOTOPIS	168
	BIOGRAPHY	170

SLIKA 2-1.	USPOREDBA VIRTUALNE STVARNOSTI I KONCEPCIJE SVEPRISUTNOG RAČUNARSTVA.	14
SLIKA 3-1.	SLIKA NASLOVNICE AMERIČKOG ČASOPISA SCIENTIFIC AMERICAN.	18
SLIKA 3-2.	SLOJEVI (STOG) SEMANTIČKOG WEBA S PRIPADAJUĆIM TEHNOLOGIJAMA.	19
SLIKA 3-3.	PRIMJER RDF GRAFA.	20
SLIKA 3-4.	PRIMJER SPARQL UPITA.	21
SLIKA 3-5.	KLASE, OBJEKTI I SVOJSTVA.	23
SLIKA 3-6.	META-PROCES RAZVOJA ONTOLOGIJA.	24
SLIKA 3-7.	PRIMJER JEDNE INTERPRETACIJE.	28
SLIKA 4-1.	SUSTAV ZA ZAKLJUČIVANJE TEMELJEN NA LOGICI.	33
SLIKA 4-2.	VENN-OVI DIJAGRAMI: PROSTOR DOGAĐAJA U.	34
SLIKA 4-3.	THOMAS BAYES (1702 – 1761).	37
SLIKA 4-4.	PROCES MODELIRANJA.	39
SLIKA 4-5.	FAZE I PROCEDURE KOD KREIRANJA BAYESOVE MREŽE.	41
SLIKA 4-6.	PRIMJER UVJETNE NEZAVISNOSTI.	41
SLIKA 4-7.	PRIMJER BAYESOVE MREŽE - TABLICE UVJETNIH VJEROJATNOSTI.	44
SLIKA 5-1.	AGENT: MODEL INTERAKCIJE.	46
SLIKA 5-2.	VIŠEAGENTSKI SUSTAV: MODEL INTERAKCIJE.	47
SLIKA 5-3.	SPOZNAJNI MODEL ZA UPRAVLJANJE GRUPOM INDUSTRIJSKIH ROBOTA.	49
SLIKA 5-4.	ARHITEKTURA SUSTAVA.	51
SLIKA 5-5.	OKOLINA KARAKTERISTIČNA ZA IZVOĐENJE POSLOVA INDUSTRIJSKOG SKLAPANJA.	52
SLIKA 5-6.	IMAGINARNI PROIZVOD (IZOMETRIJA).	53
SLIKA 5-7.	IMAGINARNI PROIZVOD (DETALJI).	53
SLIKA 5-8.	IZGLED RADNOG MJESTA.	54
SLIKA 5-9.	IZGLED OKOLINE ZA KONFIGURACIJU S DVA RADNA MJESTA.	56
SLIKA 5-10.	IZGLED OKOLINE ZA KONFIGURACIJU S TRI RADNA MJESTA.	56
SLIKA 5-11.	IZGLED OKOLINE ZA KONFIGURACIJU S ČETIRI RADNA MJESTA.	56
SLIKA 5-12.	TOPBRAID COMPOSER EDITOR.	59
SLIKA 5-13.	ALGORITAM PRVOG UZORKA PONAŠANJA (BP1).	61
SLIKA 5-14.	ALGORITAM DRUGOG UZORKA PONAŠANJA (BP2).	61
SLIKA 5-15.	ALGORITAM TREĆEG UZORKA PONAŠANJA (BP3).	63
SLIKA 5-16.	ALGORITAM ČETVRTOG UZORKA PONAŠANJA (BP4).	63
SLIKA 5-17.	ALGORITAM PETOG UZORKA PONAŠANJA (BP5).	65
SLIKA 5-18.	TAKSONOMIJA OPERACIJE MONTAŽE.	65
SLIKA 5-19.	TOPBRAID COMPOSER – HIJERARHIJSKA STRUKTURA KLASA.	65
SLIKA 5-20.	GRAFIČKI PRIKAZ TAKSONOMIJE ONTOLOŠKE JEZGE.	68
SLIKA 5-21.	TOPBRAID COMPOSER – HIJERARHIJSKA STRUKTURA SVOJSTAVA.	69

SLIKA 5-22.	DEFINICIJA ZA VIZIJSKI SENSOR TIPRA STRING.....	70
SLIKA 5-23.	DEFINICIJA ZA KAPACITIVNI SENSOR TIPRA BOOLEAN.....	70
SLIKA 5-24.	RDF TRIPLE ODNOS.....	70
SLIKA 5-25.	DIO IZVEDENE INFERRED1 KLASA KOJA SADRŽI OGRANIČENJE.....	71
SLIKA 5-26.	KLASA UZORKA PONAŠANJA BP1 S JEDNOM OD KOMBINACIJA IZLAZA SENZORA.....	71
SLIKA 5-27.	STRUKTURA SPARQL UPITA.....	72
SLIKA 5-28.	ODZIV ONTOLOŠKE JEZGRE NA DEFINIRANI UPIT.....	73
SLIKA 5-29.	INICIJALNI MODEL BAYESOVE MREŽE SOCIJALNOG KAPITALA KOD GRUPE ROBOTA.....	78
SLIKA 5-30.	RAZVOJ MREŽE – PRVI SCENARIJ, ODLUKA ZA BP1 ILI BP2, 0.....	84
SLIKA 5-31.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP1 ILI BP2, COMPETENT.....	85
SLIKA 5-32.	RAZVOJ – PRVI SCENARIJ, KORIGIRANO, ODLUKA ZA BP1 ILI BP2, 0.....	87
SLIKA 5-33.	RAZVOJ – PRVI SCENARIJ, KORIGIRANO, ODLUKA ZA BP1 ILI BP2, COMPETENT.....	88
SLIKA 5-34.	RAZVOJ – PRVI SCENARIJ, KORIGIRANO, ODLUKA ZA BP1 ILI BP2, INCOMPETENT.....	88
SLIKA 5-35.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BN1, BP2 ILI BP3, COMPETENT.....	89
SLIKA 5-36.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BN1, BP2 ILI BP3, INCOMPETENT.....	89
SLIKA 5-37.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP4, COMPETENT.....	91
SLIKA 5-38.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP4, INCOMPETENT.....	91
SLIKA 5-39.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP5, COMPETENT.....	92
SLIKA 5-40.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP5, INCOMPETENT.....	92
SLIKA 5-41.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP3, COMPETENT.....	93
SLIKA 5-42.	RAZVOJ – PRVI SCENARIJ, ODLUKA ZA BP2 ILI BP3, INCOMPETENT.....	93
SLIKA 6-1.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1 ILI BP2, 0.....	95
SLIKA 6-2.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1 ILI BP2, COMPETENT.....	95
SLIKA 6-3.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1 ILI BP2, INCOMPETENT.....	96
SLIKA 6-4.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, 0.....	97
SLIKA 6-5.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, COMPETENT.....	97
SLIKA 6-6.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, INCOMPETENT.....	98
SLIKA 6-7.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP4, 0.....	99
SLIKA 6-8.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP4, COMPETENT.....	99
SLIKA 6-9.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP4, INCOMPETENT.....	100
SLIKA 6-10.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP5, 0.....	101
SLIKA 6-11.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP5, COMPETENT.....	101
SLIKA 6-12.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP5, INCOMPETENT.....	102
SLIKA 6-13.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP3, 0.....	102
SLIKA 6-14.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP3, COMPETENT.....	103
SLIKA 6-15.	ISPITIVANJE – DRUGI SCENARIJ, ODLUKA ZA BP2 ILI BP3, INCOMPETENT.....	103
SLIKA 6-16.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1 ILI BP2, 0.....	105
SLIKA 6-17.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1 ILI BP2, COMPETENT.....	105
SLIKA 6-18.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1 ILI BP2, INCOMPETENT.....	106
SLIKA 6-19.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, 0.....	107

SLIKA 6-20.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, COMPETENT.....	107
SLIKA 6-21.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP1, BP2 ILI BP3, INCOMPETENT.	108
SLIKA 6-22.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP4, 0.....	108
SLIKA 6-23.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP4, COMPETENT.....	109
SLIKA 6-24.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP4, INCOMPETENT.	110
SLIKA 6-25.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP5, 0.....	110
SLIKA 6-26.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP5, COMPETENT.....	111
SLIKA 6-27.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP5, INCOMPETENT.	111
SLIKA 6-28.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP3, 0.....	112
SLIKA 6-29.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP3, COMPETENT.....	113
SLIKA 6-30.	ISPITIVANJE – TREĆI SCENARIJ, ODLUKA ZA BP2 ILI BP3, INCOMPETENT.	113
SLIKA 6-31.	OSJETLJIVOST BP1 (TRUE) - ZAKLJUČIVANJE NA OSTALIM ČVOROVIMA.	116
SLIKA 6-32.	SMANJENJE ENTROPIJE BP1 - UTJECAJI POJEDINOG ČVORA.....	116
SLIKA 6-33.	OSJETLJIVOST BP2 (TRUE) - ZAKLJUČIVANJE NA OSTALIM ČVOROVIMA.	117
SLIKA 6-34.	SMANJENJE ENTROPIJE BP2 - UTJECAJI POJEDINOG ČVORA.....	117
SLIKA 6-35.	OSJETLJIVOST BP3 (TRUE) - ZAKLJUČIVANJE NA OSTALIM ČVOROVIMA.	118
SLIKA 6-36.	SMANJENJE ENTROPIJE BP3 - UTJECAJI POJEDINOG ČVORA.....	118
SLIKA 6-37.	OSJETLJIVOST BP4 (TRUE) - ZAKLJUČIVANJE NA OSTALIM ČVOROVIMA.	119
SLIKA 6-38.	SMANJENJE ENTROPIJE BP4 - UTJECAJI POJEDINOG ČVORA.....	119
SLIKA 6-39.	OSJETLJIVOST BP5 (TRUE) - ZAKLJUČIVANJE NA OSTALIM ČVOROVIMA.	120
SLIKA 6-40.	SMANJENJE ENTROPIJE BP5 - UTJECAJI POJEDINOG ČVORA.....	120

POPIS TABLICA

TABLICA 3-1.	INTERPRETACIJA KONCEPATA IZ PRIMJERA SA [SLIKA 3-7].....	29
TABLICA 3-2.	INTERPRETACIJA SVOJSTAVA IZ PRIMJERA SA [SLIKA 3-7].....	29
TABLICA 4-1.	ČVOROV I VRIJEDNOSTI ZA ANALIZIRANI PRIMJER.....	42
TABLICA 5-1.	PRIKAZ OVISNOSTI IZLAZNIH O ULAZNIM VRIJEDNOSTIMA.....	60
TABLICA 5-2.	TAKSONOMIJA ONTOLOŠKE JEZGRE.....	67
TABLICA 5-3.	VARIJABLE BAYESOVE MREŽE S PRIPADAJUĆIM STANJIMA.....	75
TABLICA 5-4.	INICIJALNI POSTAV UTJECAJA VARIJABLI RODITELJA NA VARIJABLE BP_N	77
TABLICA 5-5.	VRIJEDNOSTI PRAGA I TEŽINSKIH FAKTORA ZA DVA RODITELJA.....	79
TABLICA 5-6.	TABLICA UVJETNIH VJEROJATNOSTI ZA ČVOR ORIGIN AWARENESS.....	81
TABLICA 5-7.	KORIGIRANI POSTAV UTJECAJA VARIJABLI RODITELJA NA VARIJABLE BP_N	86
TABLICA 6-1.	BP1 (TRUE) – PROSTOR VRIJEDNOSTI VJEROJATNOSTI.....	116
TABLICA 6-2.	BP1 (TRUE) – SMANJENJE ENTROPIJE.....	116
TABLICA 6-3.	BP2 (TRUE) – PROSTOR VRIJEDNOSTI VJEROJATNOSTI.....	117
TABLICA 6-4.	BP2 – SMANJENJE ENTROPIJE.....	117
TABLICA 6-5.	BP3 (TRUE) – PROSTOR VRIJEDNOSTI VJEROJATNOSTI.....	118
TABLICA 6-6.	BP3 – SMANJENJE ENTROPIJE.....	118
TABLICA 6-7.	BP4 (TRUE) – PROSTOR VRIJEDNOSTI VJEROJATNOSTI.....	119
TABLICA 6-8.	BP4 – SMANJENJE ENTROPIJE.....	119
TABLICA 6-9.	BP5 (TRUE) – PROSTOR VRIJEDNOSTI VJEROJATNOSTI.....	120
TABLICA 6-10.	BP5 – SMANJENJE ENTROPIJE.....	120
TABLICA PB-1.	JEDAN RODITELJ - VARIJABLA INTERACTION.....	138
TABLICA PB-2.	DVA RODITELJA - VARIJABLA SHARED UNDERSTANDING.....	138
TABLICA PB-3.	DVA RODITELJA - VARIJABLA ORIGIN AWARENESS.....	138
TABLICA PB-4.	DVA RODITELJA - VARIJABLA COMPETENCE AWARENESS.....	138
TABLICA PB-5.	DVA RODITELJA - VARIJABLA CAPABILITY AWARENESS.....	138
TABLICA PB-6.	ČETIRI RODITELJA.- VARIJABLA TRUST.....	138
TABLICA PB-7.	PET RODITELJA - VARIJABLA SOCIAL CAPITAL.....	138
TABLICA PB-8.	TRI RODITELJA - VARIJABLA SELF ASSESSMENT.....	139
TABLICA PB-9.	DVA RODITELJA - VARIJABLA BP1.....	139
TABLICA PB-10.	DVA RODITELJA - VARIJABLA BP2.....	139
TABLICA PB-11.	DVA RODITELJA - VARIJABLA BP3.....	139
TABLICA PB-12.	DVA RODITELJA.- VARIJABLA BP4.....	139
TABLICA PB-13.	DVA RODITELJA - VARIJABLA BP5.....	139
TABLICA PC-1.	ČVOR ATTITUDE.....	140
TABLICA PC-2.	CPT - ČVOR INTERACTIONS.....	140
TABLICA PC-3.	CPT - ČVOR SHARED UNDERSTANDING.....	141

TABLICA PC-4.	CPT - ČVOR ORIGIN AWARENESS	141
TABLICA PC-5.	CPT – ČVOR COMPETENCE AWARENESS	142
TABLICA PC-6.	CPT - ČVOR CAPABILITY AWARENESS	143
TABLICA PC-7.	CPT - ČVOR TRUST	154
TABLICA PC-8.	CPT - ČVOR SOCIAL CAPITAL	154
TABLICA PC-9.	CPT - ČVOR SELF ASSESSMENT	156
TABLICA PC-10.	CPT ČVOR BP1	157
TABLICA PC-11.	CPT - ČVOR BP2	158
TABLICA PC-12.	CPT - ČVOR BP3	158
TABLICA PC-13.	CPT - ČVOR BP4	159
TABLICA PC-14.	CPT - ČVOR BP5	160
TABLICA PC-15.	CPT - ČVOR BP1	160
TABLICA PC-16.	CPT - ČVOR BP2	161
TABLICA PC-17.	CPT - ČVOR BP3	162
TABLICA PC-18.	CPT - ČVOR BP4	163
TABLICA PC-19.	CPT - ČVOR BP5	163
TABLICA PD-1.	CPT - ČVOR BP1	164
TABLICA PD-2.	CPT - BP2	165
TABLICA PD-3.	CPT - ČVOR BP3	166
TABLICA PD-4.	CPT - ČVOR BP4	166
TABLICA PD-5.	CPT - ČVOR BP5	167

POPIS VAŽNIJIH OZNAKA I KRATICA

Oznaka	Značenje	Mjerna jedinica
Objašnjenje		
A	Atomički koncept	-
A^I	Podskup atomičkog koncepta A	-
G	Grafička struktura Bayesove mreže	-
I	Interpretacija	-
$Query$	Upit	-
R	Svojstvo atomičkog koncepta A	-
R^I	Svojstvo podskupa atomičkog koncepta A	-
S_n	Sadržaj <i>SPARQL</i> upita	-
t	Vremenski period koji označava čekanje robota	s
U	Prostor mogućih događaja koji su istiniti	-
V	Vrhovi (čvorovi) grafičke strukture	-
Z	Varijable Bayesove mreže	-
I	Interpretacijska funkcija	-
Δ^I	Domena interpretacije	-
Θ	Skup tablica uvjetnih vjerojatnosti	-

Popis kratica

$ABox$	Assertion Box
AL	Assembly Line (linija za sklapanja)
BN	Bayesian Network
BP	Behavioral Pattern
C	Conveyor (konvejer)
CA	Competence Awareness
CO	Core Ontology
CP	Capability Awareness
CPT	Conditional Probability Table

<i>CS</i>	Capacitive Sensor (kapacitivni senzor)
<i>CSS</i>	Cascading Style Sheets (stilovi)
<i>DAG</i>	Directed Acyclic Graphs
<i>DL</i>	Descriptive Logic
<i>HTML</i>	HyperText Markup Language (hipertekstualni opisni jezik)
<i>KIF</i>	Knowledge Interchange Format
<i>M+</i>	Srednje jaki, pozitivni utjecaj
<i>NP</i>	Number of Parents
<i>NS</i>	Number of States
<i>OA</i>	Origin Awareness
<i>OWA</i>	Open World Assumption
<i>OWL</i>	Ontology Web Language
<i>P</i>	Pallet (paleta)
<i>PC</i>	Part Carrier (nosač dijela)
<i>PHP</i>	PHP: Hypertext Preprocessor (predprocesor za hipertekst)
<i>R</i>	Robot (robot)
<i>RDF</i>	Resource Description Framework
<i>RDFS</i>	RDFSchema
<i>RIF</i>	Rule Interchange Format
<i>RML</i>	Rule Markup Language
<i>S+</i>	Jaki, pozitivni utjecaj
<i>SC</i>	Social Capital
<i>SP</i>	Stopping Place (zaustavno mjesto)
<i>SPARQL</i>	SPARQL Protocol and RDF Query Language
<i>SQL</i>	Structured Query Language
<i>SU</i>	Shared Understanding
<i>SWRL</i>	Semantic Web Rule Language
<i>TBC – ME</i>	TopBraid Composer – Maestro Edition
<i>TBox</i>	Terminology Box
<i>TC1</i>	Tool Changer 1 (izmjenjivač alata 1)
<i>TC2</i>	Tool Changer 2 (izmjenjivač alata 2)

<i>TR</i>	Trust
<i>TV</i>	Treshold Value
<i>Ubicomp</i>	Ubiquitous Computing (sveprisutno računarstvo)
<i>UI</i>	Artificial Intelligence
<i>URI</i>	Uniform Resource Information
<i>VS1</i>	Vision Sensor 1 (vizijski senzor 1)
<i>VS2</i>	Vision Sensor 2 (vizijski senzor 2)
<i>W+</i>	Slabi, pozitivni utjecaj
<i>W3C</i>	www consortium (www konzorcij)
<i>WF</i>	Weight Factor
<i>WP</i>	Working Place (radno mjesto)
<i>XML</i>	Extensible Markup Language

U odnosu na klasične pristupe u kojima se robotski sustavi programiraju za ograničeni broj djelovanja, sustavi koji koriste koncepte sveprisutnog računarstva mogu autonomno predviđati ponašanje u specifičnim situacijama.

U ovoj disertaciji je razvijen spoznajni model upravljanja sustavom umreženih robota zasnovan na kontekstualnoj spoznaji okoline koristeći koncepte sveprisutnog računarstva. Ti su koncepti ostvareni razvojem odgovarajuće ontologije povezane s mehanizmom odlučivanja. Razvojem ontologije za sustav robota definiran je deskriptivni model znanja karakterističan za industrijsku primjenu kod poslova robotskog sklapanja. Korišteni mehanizmi odlučivanja temeljeni su na deskriptivnoj logici ostvarenoj unutar ontologije te Bayesovoj mreži, omogućujući pritom dovoljnu razinu apstrakcije potrebnu za donošenje jednoznačnih odluka primjerenih trenutnom kontekstu.

Ključne riječi: sveprisutno računarstvo, kontekstualna spoznaja, semantika, probabilistička robotika.

Compared to classical approaches in which robotic systems are programmed for a limited number of activities, systems that rely on the concepts of Ubiquitous Computing can independently predict behaviours in specific situations.

In this thesis a cognitive model for the control of networked robots, based on the contextual perception of the environment is developed. Here, concepts of Ubiquitous Computing that are achieved by developing an appropriate ontology associated with some decision-making mechanisms are used. By developing the ontology for a system of robots, a descriptive model of knowledge to be used in industrial robotic assembly applications is defined. Decision-making mechanisms are based on Descriptive Logic achieved within the ontology and on a Bayesian Network, allowing a sufficient level of abstraction required for making unambiguous decisions appropriate to the current context.

Keywords: ubiquitous computing, contextual cognition, semantic, probabilistic robotics.

1.1. Motivacija

Robotska tehnologija ima u osnovi svrhu nadomjestiti ljudski rad, ne samo u industriji već i u drugim djelatnostima, npr. medicini, spašavanju, istraživanju, prilikom pomaganja hendikepiranim osobama, itd. Stoga se razvoj robotike sve više usmjerava prema ostvarivanju adaptivnih, antropomatskih i spoznajnih osobina [1, 2]. Robot takvih osobina mora biti sposoban interpretirati i razumjeti okolinu da bi se mogao prilagođavati stalnim promjenama koje karakteriziraju realni prostor djelovanja.

Svaki objekt, proces ili stanje po svojoj su prirodi neponovljivi. Stoga kontekst prostora i vremena postaje važna inspiracija u razvoju autonomnih sustava, predstavljajući glavne parametre promjene. Integriranje računala u okolinu kao medij koji je neprestano analizira naziva se *sveprisutno računarstvo*¹ [3, 4]. Jedan od ciljeva koncepcije *sveprisutnog računarstva* je omogućiti računalima da osjete promjene u okolini, te da se tim promjenama prilagode sukladno ugrađenom znanju o nekoj domeni problema ili djelovanja. Takav se pristup može prepoznati u spoznajnim i ponašajnim modelima² ljudi i životinja. Ljudi u osobnoj komunikaciji spontano eliminiraju sve suvišne informacije koje su trenutno nebitne za trenutni tijek razgovora. To su najčešće različiti šumovi i informacije koje dolaze iz okoline, npr. otkucaji sata u prostoriji, glasovi drugih osoba, prometna buka, temperatura prostorije i sl. Nadalje, u slučaju da se trenutni kontekst okoline promijeni, osobe u razgovoru će se po potrebu prilagoditi novim okolnostima i primjereno reagirati (npr. u prostoriji je prohladno pa se treba toplije obući i zatvoriti prozor, i sl.). Ako se razmotri priroda tih informacija po klasičnoj retoričkoj teoriji [5], okolnosti su sastavljene od vremena, prostora, događaja, uzroka, načina, osoba i alata povezanih s promatranim događajem. Na isti način, kompjutorske, odnosno, robotske aplikacije mogu biti „odgovorne“ da na temelju konteksta izvršavaju razne zadatke respektirajući ono za što su namijenjene. Navedeni pristup omogućit će sustavu da reagira na različite načine u ovisnosti o kontekstu baš kao što bi reagirao i čovjek. Univerzalna baza znanja čovjeka temelji se na osobnim i tuđim iskustvima, te na mehanizmima zaključivanja. Slično kao što je to kod ljudi, implementacija navedenog na

¹ *Ubicomp, engl. Ubiquitous Computing*

² *Biheviorističkim modelima*

tehničkim sustavima treba uključiti mehanizme koji omogućavaju donošenje odluka koje su temeljene na trenutnom kontekstu. Spoznajni model razvijen u slopu ovog rada uključuje prikupljanje i fuziju relevantnih informacija, donošenje odluka temeljenih na logici te konačnu procijenu jednoznačnog rješenja u skladu s vjerovanjima pohranjenim u Bayesovoj mreži.

U ovisnosti o skali promatranja, okolina po svojoj prirodi može biti strukturirana ili nestrukturirana. U slučaju da promatramo razinu iznad veličine atoma, ni jednu okolinu nije moguće u potpunosti definirati bez obzira na to koliko usko tolerancijsko polje upotrijebimo. Tada vrijedi konstatacija da je svaka okolina po svojoj prirodi nestrukturirana (neodređena, nedeterminirana). U slučaju da je promatrana razina veličine atoma ili manja, za sada je još nemoguće provoditi eksperimente te postavljati hipoteze bez da se ne utječe na stanje onoga što se ispituje [6]. Stoga veći dio hipoteza postavljenih u sklopu kvantne mehanike u sebi uključuje i probabilističku komponentu temeljenu na pretpostavkama i nesigurnostima. One omogućuju tek procjene vezane za smjer i prostorne koordinate analiziranih čestica. Stoga se konstatacija o nestrukturiranoj prirodi okoline sa sigurnošću može primijeniti samo u domeni koja uključuje događaje i objekte na razini većoj od veličine atoma. Imajući to na umu, prostorno vremenska domena od interesa razmatrana u sklopu ovog rada u daljnjim razmatranjima je proglašena prirodno nedeterminiranom, odnosno nestrukturiranom.

1.2. Pregled dosadašnjih istraživanja

Komponente razvijenog spoznajnog modela uključuju više znanstvenih područja, i to: robotiku, umjetnu inteligenciju, sveprisutno računarstvo, semantiku s naglaskom na njenu primijenu na računalnim mrežama, sociologiju itd. Respektirajući interdisciplinarnu prirodu spoznajnog modela, sukus istraživačkog rada stoga opisuje slične primijene iz različitih znanstvenih područja. Poseban naglasak je postavljen na primjenu u robotici.

Razvojem računarstva, sveprisutno računarstvo također bilježi značajan napredak. U najvećoj mjeri zato što senzorske i računalne, hardverske i softverske komponente bivaju sve manje, brže, jeftinije i efikasnije olakšavajući pritom smještaj uređaja u okolini baš kako nalaže vizija sveprisutnog računarstva.

Pojavom tzv. servisne robotike, koja robota definira kao entitet koji korisnicima nudi usluge, koncepcija sveprisutnog računarstva počela se sve više primjenjivati. Razvoj robotskih aplikacija temeljenih na ovim konceptima ovisi o više faktora: o lokaciji senzora, o domeni primjene, o broju korisnika, o dostupnim resursima, o korištenim hardverskim komponentama, itd. Roboti imaju više funkcionalnih komponenti: komponentu odgovornu za

izračune, senzore koji povezuju sustav s okolinom, izvršnu komponentu i sl. U skladu s mogućnostima tih komponenti, te u sklopu, tzv. *URC – Ubiquitous Robotic Companion* [7] istraživačke vizije, robot je opisan kao entitet prisutan u prostoru i vremenu uvijek spreman pružiti odgovarajuće usluge. Glavni zadatak *URC*-a je poboljšavanje mogućnosti navedenih funkcionalnih komponenti kroz mrežu robota. *URC* se velikim dijelom oslanja na teoriju sustava koja naglašava da lokalni optimumi ne moraju nužno generirati optimalno djelovanje sustava na globalnoj razini [8]. U duhu *URC-a* razvijano je nekoliko razvojnih i radnih okolina za razvoj aplikacija za robotsku percepciju konteksta okoline [9, 10]. Servisna robotika koja se danas u velikoj mjeri temelji na *URC-u*, usmjerena je na razvoj aplikacija prvenstveno za mobilnu robotiku. Odgovor zašto je to tako leži u činjenici da aplikacije realizirane unutar industrijske radne okoline na stacionarnim robotskim jedinicama ne smiju ostvarivati pogreške nastale uslijed nedeterminističke prirode okoline. Stoga se klasičnim pristupom industrijska radna okolina nastoji što je moguće više unaprijed determinirati. Kako bi utjecaj determinističkog kaosa bio sveden na minimum, spoznajni model upravljanja razvijen u ovom radu uključuje djelomično uređenu okolinu, koja pretpostavlja uređena radna mjesta. Time su stvoreni preduvjeti za korištenje principa servisne robotike koja uz principe sveprisutnog računarstva može uključivati i probabilističku komponentu.

Respektirajući razvijeni spoznajni model, daljnja podjela dosadašnjih istraživanja uključuje: dio vezan za detemiranje okoline te prikupljanje relevantnih informacija, dio vezan za semantički opis, te dio vezan za zaključivanje temeljeno na probabilitici.

Detekcija i prikupljanje informacija predstavljaju prve korake prilikom stvaranja kontekstualne spoznaje. Kako bi neki sustav mogao donositi odluke na temelju konteksta, mora posjedovati mogućnost prikupljanja informacija. Današnji senzori mogu kombinirati različite vrste podataka, kao što su zvučni i vizualni podaci, podaci o temperaturi, udaljenostima, i sl. Različiti senzori mogu koristiti različite fizikalne principe, mogu pokrivati različit prostor informacija, mogu prikupljati različite formate istih podataka pri različitim frekvencijama osvježavanja senzora. Također, prikupljene informacije mogu biti različite rezolucije, preciznosti te čak mogu biti i različito pouzdane [11, 12]. Djelomično unaprijed definirana okolina, osim rasporeda radnih mjesta u sklopu linije za sklapanje, uključuje smještaj, količinu i vrstu senzora. Na taj način je omogućeno pravovremeno i pouzdano praćenje događaja u sustavu.

Ontologije označavaju formalnu reprezentaciju entiteta u proizvoljnoj domeni zajedno s njenim pripadajućim atributima i njihovim međusobnim odnosima. Budući da omogućavaju predstavljanje proizvoljne domene, te mogu olakšati rad i razumijevanje krajnjim

korisnicima, pokazale su se izrazito prikladne. Kako je vrijeme prolazilo, pokazalo se da ontologije u svojem idejnom obliku iskazuju i određene nedostatke. U prvom redu, stručnjaci prilikom oblikovanja ontologija koriste svoja osobna znanja i iskustva što često vodi do različitih interpretacija. To opet ima za posljedicu da ontologije različitih eksperata koje opisuju dijelove iste domene često ne mogu međusobno razmjenjivati informacije. Projekti *MASON* [13] i *ONTOMAS* [14] predstavljaju nastojanja istraživača da naprave ontologije koje opisuju proizvodne djelatnosti. Navedene ontologije koristi više autora u svojim aplikacijama [15]. Iako postoji mogućnost prilagodbe dijelova tih ontologija za potrebe ovog rada, navedene ontologije kao gotova rješenja su se pokazale kao nedovoljno precizne kod aktivnosti koje uključuju operacije robotskog sklapanja. Kako bi se postigla kompatibilnost s njima te zadržala mogućnost kasnije nadogradnje i na ostala područja proizvodnih djelatnosti, prilikom izrade ontologije za potrebe ovog rada korišten je dio taksonomije robotskog sklapanja opisan u [16].

Drugi nedostatak je proizašao iz činjenice da ontologijama nedostaje podrška za opisivanje stanja koja po svojoj prirodi nisu jednoznačno definirana. U nedeterminističkom svijetu, deterministički ontološki opis sam po sebi vrlo često nije dovoljan. U svojim nastojanjima da neutraliziraju navedene nedostatke, dio istraživača se okrenuo razvoju i primjeni probabilističkih pristupa. Kao idealan izbor pokazale su se Bayesove mreže, koje mogu opisati složene povezane distribucije koristeći skup lokalnih distribucija [17]. Rad [18] daje uvid u istraživanja i primjere vezane za objedinjavanje Bayesovih mreža i ontologija. Autori su identificirali četiri recentna smjera istraživanja, i to: izrada Bayesovih mreža iz ontologija [19, 20, 21, 22, 23], uporaba Bayesovih mreža prilikom povezivanja različitih ontologija [24, 25, 26], probabilističku ekstenziju *OWL-a* (engl. *Ontology Web Language*) [27, 28], te poboljšavanje ontoloških mehanizama zaključivanja uporabom Bayesovih mreža [29]. Prilikom izrade disertacije korišteni su formalizmi koji se mogu povezati s četvrtim područjem istraživanja.

Metode temeljene na probabilitici u robotici se koriste u slučajevima gdje se nalaze nesigurnosti i/ili neodlučnosti. Prije svega to su problemi robotskog planiranja i kontrole te problemi lokalizacije kod mobilnih robota [30]. Neodlučnost identificirana u sklopu ovog rada nalazi se prije svega u podjeli posla među robotima u grupi čime se ne utječe na točnost izvođenja operacija već na optimalan rad sustava u cjelini. Kroz primjere u radu [31] opisana je metodologija pomoću koje je moguće pristupiti razvoju sličnih spoznajnih modela koji koriste ontologije i Bayesove mreže za izradu inteligentnih robotskih servisa. Iako

metodologija nije direktno primjenjiva na domenu primjene robota u industriji, navedene smjernice djelomično su korištene prilikom kreiranja Bayesove mreže za potrebe ovog rada.

Pronaći nesigurnosti na temelju kojih robot, pripadnik grupe koja djeluje u industrijskoj radnoj okolini, gdje većina procesa mora biti deteminirana i savršeno izvedena nije uvijek baš jednostavno. Model Bayesove mreže razvijen u sklopu ovog rada inspiriran je fenomenom socijalnog kapitala [32] koji je identificiran kod ljudskih zajednica i predstavlja potencijal grupe za zajednički rad. Temelj socijalnog kapitala je interakcija koja vodi ka stvaranju povjerenja i dijeljenju ideja što utječe na krajnju izvedbu cijele grupe (sinergija djelovanja). Na temelju istraživanja, grupa autora [33] identificirala je varijable te modelirala Bayesovu mrežu za ocjenjivanje potencijala ljudske zajednice prilikom obavljanja zajedničkih zadataka. Na sličan način su identificirane varijable te definirani utjecaji koji su značajni prilikom zajedničkog rada grupe robota u industrijskoj radnoj okolini u sklopu ovog rada. Odluke temeljene na vjerovanjima (nesigurnostima) koje predstavljaju jezgru razvijene Bayesove mreže ovise o (samo)procjeni kompetencija robota koji izvodi zadatak te procjenama socijalnog kapitala kod cijele grupe.

Internet se pokazao kao specifična domena za razvoj velikog broja „pametnih“ aplikacija temeljenih na semantici [34]. Članak [35] opisuje medicinski sustav koji na temelju kontekstualnih informacija o instrumentima u operacijskoj sali može prepoznati u kojoj je fazi operacija. Slična primjena se može pronaći i kod sustava za određivanje terapijskih preporuka [36].

Prema definiciji [37], web servisi označavaju tehnologiju koja podržava interakciju među agentima uz pomoć programske podrške te mrežnih komunikacijskih protokola temeljenih na web tehnologiji. Njihova primjena u sklopu industrijskih sustava je područje na kojemu se trenutno jako puno radi. Najveći problemi leže u neusklađenosti postojećih softverskih i hardverskih komponenti s web tehnologijom [38, 39]. Kako bi se to uskladilo, postupci simulacije i evaluacije razvijenog modela provedeni su na osobnom računalu koristeći alate temeljene na web servisima. Time su stvoreni preduvjeti za kasniju implementaciju modela u stvarnoj industrijskoj okolini.

1.3. Cilj i hipoteza rada

Cilj istraživanja je razvoj spoznajnog modela pomoću kojeg će sustav robota posjedovati dovoljnu razinu apstrakcije za donošenje odluka o svojem djelovanju (ponašanju).

Težište disertacije je postavljeno na razvoj formalizama za odlučivanje temeljenih na ontologiji, deskriptivnoj logici [40] i Bayesovim mrežama [41], te na stvaranju ontološke

jezgre koja sadrži ekspertna znanja karakteristična za primjenu robota u industriji na poslovima sklapanja. Ontologija opisuje okolinu zajedno s robotskim programskim strukturama koje se koriste u ovisnosti o trenutnom kontekstu te vjerovanjima ugrađenim u probabilistički dio modela.

Kontekst predstavlja bilo koju informaciju koja može biti korištena prilikom karakterizacije nekog entiteta. Entitet može biti osoba, mjesto, objekt ili aplikacija koja je relevantna za interakciju među komponentama domene. Možemo reći da je neki sustav svjestan konteksta ako ga koristi prilikom razmjene relevantnih informacija i/ili servisa između entiteta. Takvi sustavi mogu biti implementirani na najrazličitije načine. Pristup implementaciji ovisi o specifičnim zahtjevima te o parametrima kao što su položaj senzora, broj korisnika, dostupnost resursa, mogućnost proširenja, i sl. [42].

Prilikom kontekstualne percepcije okoline razvijeni spoznajni model s ekspertnim znanjima koristi više agenata – robotskih jedinica. Radna domena je opisana pomoću jezika *OWL* [43]. Navedeni jezik koristi se najčešće na webu i to u sklopu, tzv. semantičkog weba. Prilikom izrade *OWL* ontološke baze, kao alat je korišten *TopBraid Suit* [44]. Navedena aplikacija imaju relativno velik broj korisnika, te sadržavaju veći broj modula razvijenih za različite namjene te podržava rad s deskriptivnom logikom.

Deskriptivna ili opisna logika [45] je naziv za porodicu formalizama za predstavljanje znanja u kojima se definiraju relevantne klase u domeni, njihova svojstva, relacije među klasama, individue u domeni te relacije među njima. Prilikom korištenja deskriptivne logike vrlo je važno što točnije opisati domenu. Zbog toga što slijedi, tzv. pretpostavku otvorenog svijeta, semantika deskriptivne logike dozvoljava mogućnost da dio informacija u sustavu nedostaje. U tim slučajevima sustav ostaje bez konačne odluke što vodi do zaključka da odluke koje sustav donosi nisu probabilističke prirode. Tada spoznajni model donosi odluke uz pomoć ranije definirane Bayesove mreže. Pomoću nje moguće je izračunati očekivanja nepoznatih varijabli koristeći od ranije poznate varijable. Da bi to bilo moguće potrebno je odrediti koji su zaključci najvjerojatniji s obzirom na trenutno dostupne informacije. Recentni popis alata za modeliranje Bayesovih mreža nalazi se na referenci [46].

Kontekstualna spoznaja podrazumijeva shvaćanje domene problema u širem smislu od percepcije pojedinog agenta (robota, djelujućeg sustava, softvera, itd.), a postiže se u interakciji s okolinom koja uključuje jednako objekte, zbivanja, ali i druge agente, postajući tako „*Ubiquitous*“ (prožimajuća, sveprisutna). Na temelju iznesenog moguće je postaviti sljedeću hipotezu:

Pretpostavlja se da je razvojem ontologije za sustav robota, te mehanizama odlučivanja temeljenih na deskriptivnoj logici i Bayesovoj mreži moguće oblikovati formalni, prilagodljiv i zajednički spoznajni model upravljanja grupom robota karakterističan za industrijsku primjenu kod poslova robotskog sklapanja proizvoda. Model upravljanja je:

- formalan, jer će biti napisan jezikom razumljivim svim komponentama sustava,
- prilagodljiv, jer će omogućiti odabir i/ili promjenu obrazaca ponašanja u odnosu na trenutni kontekst i fazu izvođenja zadataka,
- zajednički, jer će ga koristiti sve komponente sustava.

U odnosu na klasičnu primjenu robota, razvoj spoznajnog modela upravljanja omogućit će efikasniju prilagodbu robotskog sustava na promjene.

1.4. Metodologija istraživanja

Sva oprema potrebna za realizaciju predloženog istraživanja nalazi se na Fakultetu strojarstva i brodogradnje, Sveučilišta u Zagrebu, u Laboratoriju za projektiranje izradbenih i montažnih sustava.

Radna domena je opisana pomoću *OWL* jezika (engl. *Ontology Web Language*) uz pomoć *TopBraid Composer* editora. Prilikom izrade i ispitivanja Bayesove mreže korišteni su *Genie* i *Smile*. *Smile* je *C++* biblioteka za razvoj i rad s Bayesovim mrežama. *Genie* predstavlja korisničko sučelje koje omogućava primjenu biblioteke za korisnike koji žele na pristupačan način pomoću grafičkog sučelja razvijati i testirati Bayesove mreže.

Eksperimentalno istraživanje je provedeno simulacijom primjera okoline koja uključuje konfiguracije sustava robota za sklapanje s dva, tri i četiri robota u grupi.

Planirana istraživanja su provedena u tri faze. U prvoj fazi istraživanja je unaprijed determinirana radna okolina karakteristična za poslove grupnog robotskog sklapanja. Navedena okolina služi za dokazivanje metodologije razvijenog modela. Spoznajni model je moguće razviti i za proizvoljnu konfiguraciju okoline sve dok se koristi metodologija razvoja modela opisana u ovom radu. Tako je radna okolina podijeljena na dva glavna dijela: na liniju za sklapanje i na radna mjesta. Linija za sklapanje (*AL* – engl. *Assembly Line*) omogućuje transport nosača dijelova (*PC* – engl. *Part Carrier*) između radnih mjesta. Jedno radno mjesto (*WP* – engl. *Working Place*) sadržava konvejer (*C* – engl. *Conveyor*), paletu (*P* – engl. *Pallet*), zaustavno mjesto (*SP* – engl. *Stopping Place*), vizijski senzor smješten iznad zaustavnog mjesta (*VSI* – engl. *Vision Sensor I*), robota (*R* – engl. *Robot*), vizijski senzor

smješten na robotu (*VS2* – engl. *Vision Sensor 2*), izmjenjivač alata (*TC* – engl. *Tool Changer*) i kapacitivni senzor (*CS* – engl. *Capacitive Sensor*). Skraćenice proizašle iz engleskih naziva komponenti sustava su korištene zbog kompatibilnosti s ontologijama koje su razvijene od strane drugih autora. Budući da jedno radno mjesto sadržava jednog robota, grupni robotski rad podrazumijeva korištenje barem dva ili više radnih mjesta. Okolina je definirana u skladu s principima skalabilnosti što znači da dodavanjem novih radnih mjesta (*WP*), možemo povećavati kapacitet sustava u cjelini. Prilikom dodavanja novog radnog mjesta ne zadire u ontološku definiciju radne okoline. Dodavši klasu *WP*, sustav istovremeno dobije sve podklase navedene klase kao što su: *R* (robot), *SP* (zaustavno mjesto), *VSI* (vizijski senzor 1), itd.

Sljedeća prednost navedenog pristupa leži u sposobnosti sustava da se prilagodi trenutnoj ili trajnoj nemogućnosti pojedinog radnog mjesta da obavi svoju primarnu zadaću, npr. uslijed kvara neke od komponenti ili pomanjkanja (nepostojanja) odgovarajućeg alata. U tome slučaju ostala radna mjesta mogu nastaviti sklapanje serije proizvoda budući da su sastavljena od funkcionalno istih, odnosno sličnih sastavnica (svojstvo samoodrživosti – engl. *self-healing, auto-recovery or self-protecting*). Također, robot koji nije u mogućnosti izvršiti operacije koje se od njega očekuju, prilikom slanja upita poslat će informaciju o svojoj kompetentnosti koja će utjecati na daljnje odluke unutar probabilističkog dijela spoznajnog modela.

Posljednju i svakako ne najmanje važnu prednost ovog pristupa moguće je pojmiti u načinu uporabe senzora prilikom prikupljanja relevantnih informacija. Senzori su smješteni tako da omogućuju potrebne, pravovremene i nedvosmislene informacije o prostornom i vremenskom stanju okoline. Osim što je time domena od interesa postala stalno analizirani prostor što je u skladu s načelima, tzv. sveprisutnog računarstva, stvoreni su preduvjeti za razvoj, tzv. aplikacija svjesnih konteksta (engl. *context-aware*). Aplikacije te vrste analiziraju pitanja kao što su *tko, gdje, kada i što* od entiteta, te koriste te informacije prilikom određivanja *zašto*. Ljudski razgovor je jako dobar primjer uzet iz stvarnog svijeta. Kada dvoje ili više ljudi razgovaraju koriste relativno veliku količinu informacija. Oni analiziraju, prosuđuju i predviđaju gotovo sve, počevši od govora tijela i svih ostalih vremenskih i/ili prostornih, bliskih i/ili udaljenih informacija. Budući da ljudi prilikom komunikacije dijele to znanje vezano za trenutnu situaciju, nemaju ga potrebe učiniti eksplicitnim. Na žalost, računala ne dijele implicitno znanje zajedno s ostalim relevantnim faktorima unutar ciljane domene. Smještajem senzora u domenu problema na navedeni način stvoreni su preduvjeti da

se pomoću spoznajnog modela podrži prijelaz s implicitnog ka eksplicitnom, omogućivši pritom sustavu donošenje odluka temeljenih na implicitnim informacijama.

Druga faza istraživanja uključuje razvoj tri glavna dijela spoznajnog modela: sakupljanje informacija is okoline, razvoj ontološke baze te razvoj Bayesove mreže. Ontološka baza sadržava ekspertna znanja karakteristična za primjenu robota u industriji kod poslova sklapanja. Razvoj ontologije temelji se na unaprijed djelomično determiniranoj radnoj okolini te uključuje opis svih već navedenih komponenti. Ontologija sadržava i, tzv. uzorke ponašanja (*BPs* – engl. *Behavioral Patterns*). Uzorak ponašanja označava programski slijed instrukcija definiran algoritmom koji robot treba izvršiti kao odziv na trenutno stanje okoline. Zamišljeno je da svaki robot posjeduje pohranjen isti skup uzoraka koji se pokreću u ovisnosti o trenutnom kontekstu. U slučaju da neki robot nema na raspolaganju sve uzorke ponašanja, u sklopu upita će poslati informaciju o svojoj kompetentnosti. Semantika deskriptivne logike omogućuje stvaranje logičkih izraza unutar ontologije. Na taj su način klase i pripadajući objekti navedeni u taksonomiji povezani u logičkim izrazima. To omogućuje spoznajnom modelu da preslika informacije dobivene sa senzora u izlaze na željeni način. Budući da slijedi, tzv. pretpostavku otvorenog svijeta, semantika deskriptivne logike dozvoljava više rješenja u pogledu djelovanja (odabir više mogućih uzoraka ponašanja), jer se pretpostavlja da senzori ne mogu u potpunosti preslikati stvarno stanje okoline ili pak njihova interpretacija može biti višeznačna. U tim bi slučajevima robot postao neodlučan budući da trenutno postoji više mogućih modela ponašanja. Respektirajući kompetencije robota koji postavlja upit, te socijalni kapital kojim se procjenjuju mogućnosti grupe, Bayesova mreža omogućuje robotu odabir jedinstvenog rješenja. Pomoću nje je moguće izračunati očekivanja nepoznatih varijabli koristeći od ranije poznate varijable. To uključuje određivanje najvjerojatnijih zaključaka s obzirom na trenutno dostupne informacije.

Nakon implementacije spoznajnog modela, u trećoj fazi se objedinjuju spoznaje iz prethodnih faza. Uz to, ova faza obuhvaća eksperimentalni dio te verifikaciju i validaciju predložene metodologije. Validacija i verifikacija spoznajnog modela izvode se simulacijama uz promjenu ulaznih parametara. Kao glavni kriteriji ispituju se svojstva samoodrživosti i skalabilnosti sustava, te sposobnost modela da interpretira kontekst okoline u skladu s očekivanjima. Budući da je dio spoznajnog modela temeljen na probabilistici, u ovisnosti o predočenim dokazima pojavljuju se različite odluke robota u grupi uz isto inicijalno stanje okoline. Ove su spoznaje poslužile za daljnje profiliranje parametarskog prostora Bayesove mreže, te u konačnici i završetak razvoja spoznajnog modela.

1.5. Očekivani znanstveni doprinos

Znanstveni doprinos ostvarenog istraživanja sastoji se u razvoju spoznajnog modela koji omogućuje robotu unutar grupe da donosi odluke temeljem kontekstualnih informacija koristeći semantički opis domene od interesa te probabilističko zaključivanje ostvareno kroz Bayesovu mrežu. Domena od interesa je industrijska radna okolina u kojoj grupa stacionarnih industrijskih robota izvršava poslove sklapanja proizvoda. Razvoj Bayesove mreže kao dijela spoznajnog modela, inspiriran je fenomenom socijalnog kapitala kod ljudskih zajednica koji služi kao mjera potencijala grupe ljudi za uspješan timski rad. Na ovaj način robot, kao umjetna tvorevina smještena unutar grupe sličnih, ostvaruje “ponašanje” koje je usporedivo s onim kod pojedinaca unutar ljudskih zajednica. Na temelju iscrpnih simulacijskih provjera utvrđeni su trendovi promijena parametara Bayesove mreže u ovisnosti o različitim pretpostavkama i vjerovanjima ljudskog stručnjaka koji definira početne parametre.

1.6. Struktura rada

Disertacija je strukturirana kako slijedi:

- U prvom, uvodnom poglavlju, problematika razvoja spoznajnog modela je stavljena u kontekst recentnih istraživanja respektirajući sve sastavnice modela. Time su istražene značajnije primjene metodologije sveprisutnog računarstva, semantike te probabilitike kako u uslužnoj, tako i u industrijskoj robotici. Identificirane su dobre i loše strane čime su koncipirane teoretske osnove koje su poslužile za kasnije usmjeravanje razvoja modela. Na temelju tih spoznaja, formulirana je hipoteza rada, predstavljena metodologija istraživanja, te izložen znanstveni doprinos disertacije.
- Drugo poglavlje, *Sveprisutno računarstvo* sadrži pregled područja s posebnim osvrtom na sustave svjesne konteksta budući da je jedna od osobina koju robot unutar grupe treba ostvariti kroz primjenu spoznajnog modela, upravo djelomička kontekstualna spoznaja okoline te donošenje odluka koristeći kontekstualne informacija.
- U trećem poglavlju, koje nosi naziv *Prikaz znanja zasnovan na ontologijama*, objašnjena je motivacija zašto je dio spoznajnog modela temeljen upravo na tehnologiji semantičkog weba. Kroz poglavlje su predstavljene ontologije kao alat za pohranu znanja o proizvoljnoj domeni interesa. Također, navedeni su programski jezici semantičkog weba, kao što su *OWL*, *SPARQL* i *RDFShema*, koji

su kasnije korišteni prilikom razvoja spoznajnog modela. Poglavlje sadrži i opis meta-procesa razvoja ontologija, pomoću kojeg je moguće kroz nekoliko faza razviti jasnu i preglednu ontologiju čija izražajnosti, te korištena tehnologija odgovara potrebama ciljane primijene. Poglavlje završava s predstavljanjem deskriptivne (opisne) logike kao formalizma na kojem se temelje mehanizmi zaključivanja unutar ontologija.

- Četvrtim poglavljem u rad su uvedene teorijske osnove potrebne za razvoj probabilističkog dijela spoznajnog modela koji je korišten za donošenje jednoznačnih odluka temeljenih na vjerovanjima i procjenama. U poglavlju je dan osvrt na probabilitiku kao dio umjetne inteligencije koja predstavlja dominantni izvor inspiracija prilikom razvoja algoritama, tj. upravljačkih programa u robotici. Kroz matematičku formulaciju i primjer, uz Bayesov teorem je objašnjena i metodologija razvoja Bayesovih mreža.
- Peto poglavlje daje cjelovit i iscrpan pregled razvoja spoznajnog modela, počevši od pojmova agenta i višeagentskog sustava povezujući ih s djelovanjem robota unutar grupe. Poglavlje sadrži prikaz arhitekture budućeg postava sustava u sklopu realne okoline. U ovom poglavlju dana je matematička i opisna formulacija spoznajnog modela zajedno sa svim svojim sastavnicama. Spoznajni model je analiziran s različitih gledišta, uzimajući u obzir sveprisutnu okolinu u kojoj je grupa robota smještena, ontološku jezgru unutar koje je semantički opisana domena od interesa, te zaključivanje temeljeno na Bayesovoj mreži. Poglavlje sadrži cjelovitu metodologiju razvoja modela i predstavlja uvod u sljedeće poglavlje u kojem je provedena validacija i verifikacija.
- Poglavlje šest bavi se validacijom i verifikacijom predložene metodologije na način da je model ispitan kroz dva scenarija. Provedena je i analiza osjetljivosti spoznajnog modela u sklopu koje su analizirani čvorovi mreže te njihovi međusobni utjecaji postupkom koji mjeri smanjanje entropije unutar modela. Na temelju rezultata analize, razmatrana je mogućnost podešavanja vrijednosti tablica uvjetnih vjerojanosti čvorova mreže kod implementacije modela u realnoj okolini.
- Sedmo poglavlje je zaključno. U njemu se rekapituliraju polazne postavke provedenog istraživanja i dovode u vezu s rezultatima dobivenim kroz simulacije. Kritički se osvrće na dobivene rezultate te se predlažu smjerovi budućeg istraživanja.

- Popis korištenih bibliografskih jedinica nalazi se u osmom poglavlju.
- *Prilozi A, B, C i D* sadrže *OWL* programski kod uzoraka ponašanja, izračun težinskih faktora, izračun vrijednosti uvjetnih vjerojatnosti te izračun korigiranih vrijednosti uvjetnih vjerojatnosti, respektivno.

“ *Don't say that something can't be done. I don't care. I am just a dreamer!* ”
José Barata

2.1. Vizija sveprisutnog računarstva

Sveprisutno računarstvo je pojam koji označava treće poglavlje u evoluciji modernog računarstva [47]. Prvo poglavlje karakterizira uporaba manjeg broja velikih, centralnih i dijeljenih (tzv. *mainframe*) računala na koja su spajani terminali za pristup. Glavna osobina ove ere računarstva je ostvarivanje istovremene interakcije više korisnika s jednim računalom. Drugo poglavlje u razvoju računarstva pripada uporabi, tzv. osobnih računala (*PC* – engl. *Personal Computer*). U sklopu ove ere omogućen je pristup računalima za sve one korisnike koji su ih mogli priuštiti. Navedeni pristup je rezultirao interakcijom korisnik – računalno (tzv. interakcija jedan na jedan). Treće, odnosno posljednje poglavlje pripada eri, tzv. sveprisutnog računarstva (engl. *Pervasive* ili *Ubiquitous Computing* – *UbiComp*) koje podrazumijeva smještaj računala (uređaja, strojeva, osobnih računala, pametnih telefona i sl.) u okolinu koja se potom konstantno analizira. Budući da se radi o međusobno povezanim uređajima od kojih svaki može imati jednu ili više funkcija, ostvaruje se interakcija korisnik – više računala (tzv., interakcija jedan na više). Stoga je moguće definiciju sveprisutnog računarstva predstaviti kao:

model interakcije između čovjeka i računala, odnosno između dva ili više računala gdje je procesiranje informacija integrirano u okolinu, objekte i/ili aktivnosti.

Sveprisutno računarstvo objedinjuje velik broj istraživačkih područja i to: distribuirano računarstvo³, mobilno računarstvo⁴, mreže senzora⁵, interakciju čovjek – računalno⁶ i umjetnu inteligenciju⁷. Koristeći metode koje se temelje na viziji sveprisutnog računarstva, okolina postaje prostor konstantno analiziran uređajima koji mogu primijetiti (osjetiti, detektirati i sl.) značajne promijene koje potom mogu potaknuti sustav da reagira u ovisnosti o njegovoj

³ *Distributed Computing*

⁴ *Mobile Computing*

⁵ *Sensor Networks*

⁶ *Human – Robot Interaction*

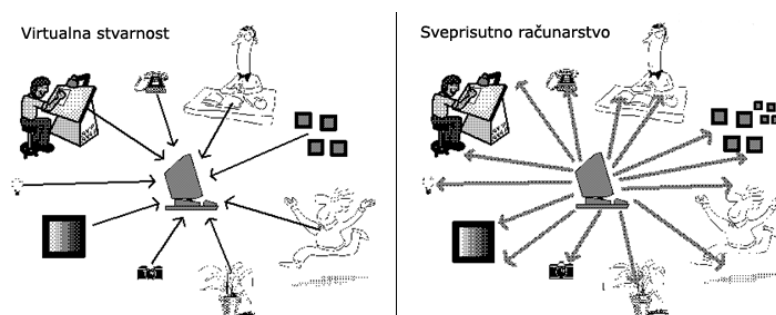
⁷ *Artificial Intelligence*

prvotnoj namjeni. Aplikacije koje su razvijane u skladu s navedenom vizijom obično imaju mogućnost djelomično percipirati kontekst, gdje kontekst može uključivati informacije o lokaciji nekog objekta, aktivnostima, ciljevima, izvorima resursa, stanju uma i sl. Još je Mark Weiser, koji se smatra ocem *ubicom* pristupa računarstvu, 1988. godine, dok je radio kao direktor jednog od laboratorija Xerox PARK-a [48], predvidio uporabu, tzv. „pametnih“ uređaja čijeg postojanja korisnik i ne mora biti svjestan. Posebno vizionarskim se pokazao jedan od njegovih citata objavljen u [49]:

tehnologije koje su po svojoj definiciji najbliže značenju riječi sveprisutne su one koje se stope sa svojom okolinom. One se utkaju u tkivo svakodnevnog života sve dok ih više nije moguće razaznati.

Srž Weiserove vizije je komunikacija između mobilnih i/ili ugrađenih računala zajedno s okolnom infrastrukturom, besprijekorno koordinirajući svoje akcije te pružajući podršku za različite poslove.

Koncepciju sveprisutnog računarstva moguće je shvatiti i kroz usporedbu s prividnom stvarnošću. Dok prividnom stvarnošću okolinu želimo modelirati na računalu, koncepcija sveprisutnog računarstva radi upravo suprotno – računala se integriraju u okolinu tako da putem senzora prikupljaju informacije i stvaraju vlastiti model okoline i djelovanja. Slika [Slika 2-1] prikazuje prividnu stvarnost kao dijametralno različit pristup u odnosu na pristup sveprisutnog računarstva.



Slika 2-1. Usporedba virtualne stvarnosti i koncepcije sveprisutnog računarstva.

Na temelju iznesenih definicija i razmišljanja može se zaključiti da je spoznajni model razvijen u ovom radu u skladu s vizijom sveprisutnog računarstva budući da dio svojih odluka (ontološka jezgra modela) koristi senzore smještene u okolinu. Unutar spoznajnog modela informacije eksplicitne prirode se interpretiraju na način da roboti (računala) mogu “shvatiti” prirodu trenutnog konteksta okoline te donositi odluke koje su u skladu s vjerovanjima stručnjaka koji je razvijao model.

2.2. Sustavi svjesni konteksta

Prije rasprave o kontekstualnoj spoznaji okoline dobro je imati na umu definiciju konteksta. Između brojnih definicija koje se mogu pronaći u literaturi, Dey i Abowd [50] kontekst definiraju kao:

bilo koju informaciju korištenu prilikom karakterizacije nekog entiteta. Entitet može biti osoba, mjesto ili objekt koji se smatra relevantnim kod interakcije između korisnika i aplikacije, uključujući i njih same.

Respektirajući navedenu definiciju moguće je zaključiti da sustav koji svoje odluke temelji na kontekstualnoj spoznaji nije prisiljen koristiti samo informacije pristigle kroz, tzv. komunikacijski kanal, već ih može kombinirati na različite načine stvarajući pritom odgovarajuća značenja. Kontekstualna spoznaja podrazumijeva shvaćanje domene problema puno šire nego što ga jedan agent (osoba, robot, program, itd.) može sagledati. To shvaćanje je moguće ostvariti kroz interakciju između agenta i okoline zajedno sa svim relevantnim objektima, drugim agentima, procesima i događajima.

Može se reći da je sustav svjestan konteksta (engl. *Context-aware system*) ako ga koristi prilikom pružanja informacija i/ili servisa u ovisnosti o stvarnim potrebama korisnika. Aplikacije svjesne konteksta analiziraju pitanja kao što su *tko, gdje, kada* i *šta* od entiteta, te ih koriste prilikom određivanja *zašto* [51]. Ljudski razgovor je jako dobar primjer uzet iz stvarnog svijeta. Kada dvoje ili više ljudi razgovaraju, koriste sve dostupne i relevantne informacije. Oni analiziraju, prosuđuju i predviđaju gotovo sve, počevši od govora tijela te svih ostalih vremenskih i/ili prostornih, bliskih i/ili udaljenih informacija. Proces stvaranja zajedničkog razumijevanja među jedinkama u komunikaciji u stručnoj terminologiji naziva se “polaganje temelja” (engl. *grounding*) [52]. Budući da ljudi prilikom komunikacije dijele znanje vezano za trenutnu situaciju nema potrebe pojednostavniti ga, odnosno učiniti ga eksplicitnim. Na žalost računala ne dijele implicitno znanje zajedno s ostalim relevantnim objektima unutar ciljane domene. Smještajem senzora u domenu interesa na prikladan način mogu biti stvoreni uvjeti da se pomoću razvijenog spoznajnog modela podrži prijelaz s implicitnog ka eksplicitnom, omogućivši pritom sustavu da donosi odluke temeljene na implicitnim informacijama. Na taj način robot u grupi može dobiti mogućnost da zaključuje neovisno, dijeli svoje zaključke te nudi servise oslanjajući se na strukturirane, odnosno kontekstualne informacije.

Razvijeni i primijenjeni spoznajni model dao je robotima mogućnost da donose odluke po uzoru na živa bića, odnosno ljude. Znanje i očekivanja ugrađena u model oslikavaju znanje i

vjerovanja osobe koja je gradila model. Očekivano je vjerovati da će takav model donositi iste ili slične odluke kao i njegov tvorac. Navedeni subjektivizam se može ublažiti na način da prilikom izgradnje modela sudjeluje tim ljudi kreirajući objektiviziranu bazu znanja koja predstavlja zajednička i nepristrana vjerovanja o značenjima konteksta unutar ciljane domene.

3. PRIKAZ ZNANJA ZASNOVAN NA ONTOLOGIJAMA

“ *All traditional logic habitually assumes that precise symbols are being employed. It is therefore not applicable to this terrestrial life but only to an imagined celestial existence.* ”

Bertrand Russell

3.1. Vizija semantičkog web-a


Izvorni (klasični, sintatički), odnosno web⁸ kakav je u najvećoj mjeri poznat i danas, predstavlja tek jednu od usluga na Internetu. Zamišljen je kao informacijsko-komunikacijski medij za prezentaciju, odnosno razmjenu informacija. Web je temeljen na principu hiperlinkova. Napravljen je pomoću tehnologija kao što su *HTML*, *CSS*, *JavaScript*, *PHP*, *MySQL* i sl. Uključujući više od trilion stranica i bilion korisnika, web danas predstavlja jedan od najuspješnijih artefakata ikada kreiranih ljudskom rukom. Krajem 2009. postojalo je 234 milijuna web sjedišta od kojih je u toj godini nastalo 47 milijuna [53]. Sve te informacije (web stranice koje mogu sadržavati tekst, sliku ili multimedijalni sadržaj) bile su kreirane i kreiraju se još i danas s ciljem da ih koriste primarno ljudi. U tome leži jedan od glavnih nedostataka sintatičkog weba: informacije su prilagođene ljudima i kao takve nisu razumljive računalima. Nasuprot tome, semantička tehnologija omogućuje smještaj informacija na mreži u formi djelomično razumljivoj računalima. Originalna vizija tvorca weba, Tim Berners-Lee-a bila je puno ambicioznija i može se reći gotovo vizionarska:

kada bi interakcija ljudi i hiperteksta mogla biti dovoljno intuitivna na način da informacije koje računala mogu čitati budu dovoljno precizne te da mogu opisivati ljudska djelovanja, misli i radne navike, tada bi računala postala snažan alat koji može pomoći prilikom rješavanja ljudskih svakodnevnih poslova kao što su, npr. upravljanje velikim organizacijama i sl. [54].

Svoju viziju evolucije sintatičkog weba u semantički, Tim Berners-Lee je dodatno opisao 2001. u legendarnom broju časopisa *Scientific American* [Slika 3-1], [55]. Zamišljeno je da

⁸ engl. *World Wide Web*, skraćeno *WWW*, *W3* ili *Web*

semantički web bude ekstenzija sintatičkog, zadržavajući pritom sva ranije implementirana svojstva, standarde i funkcionalnosti. Navedena tehnologija omogućuje zajednički rad računala i ljudi proširujući pritom područje primjene mehanizama semantičkog weba na sve umrežene uređaje. Zadnjih nekoliko godina se intenzivno radilo na prilagodbi, odnosno transformaciji postojećih te izradi novih dokumenata prema standardima *W3* konzorcija⁹ [56].

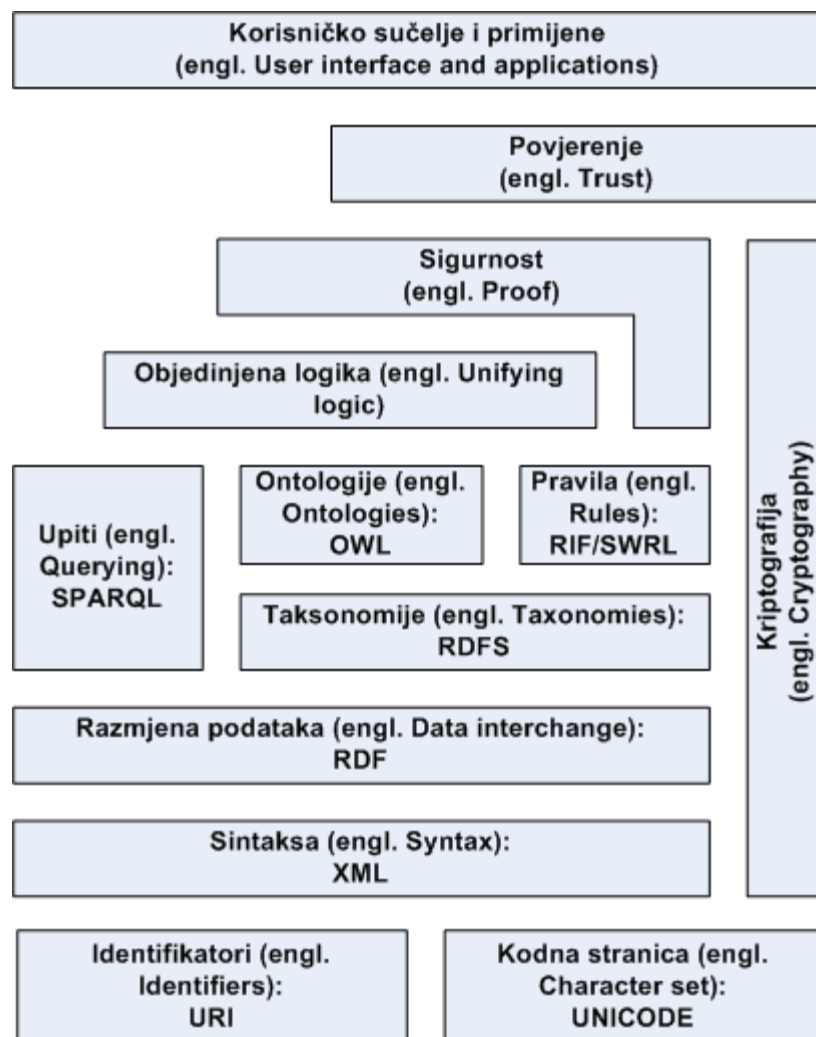


Slika 3-1. Slika naslovnice američkog časopisa Scientific American.

Principi koje koristi semantički web su implementirani u slojeve na način da se svaki novi sloj gradi na već postojećem. Slojevi u osnovi sadržavaju standarde i regulative koje definiraju različite aspekte tehnologije semantičkog weba. Na taj način je omogućen razvoj tehnologije u malim koracima s ciljem fokusiranog rada istraživačkih grupa na trenutnim problemima. Prilikom razvoja jednog sloja koriste se dva glavna principa [57]. Prvi princip zahtjeva da agenti (programi) koji koriste razvijeni sloj moraju moći interpretirati informacije pisane za sloj koji se nalazi na razini ispod. Drugi princip govori o djelomičnom razumijevanju slojeva koji se u hijerarhiji nalaze iznad. U ovom slučaju se zahtjeva barem djelomično razumijevanje informacija koje egzistiraju na tim slojevima kako bi se zadržala kompatibilnost te omogućila povezanost među udaljenim slojevima. Do sada je razvijano više varijanti prikaza strukture slojeva, i to od izvorne vizije tvorca weba Tim Berners-Lee-a pa do verzije [Slika 3-2] koju je prihvatio *W3C*, 2006. Osim slojeva, slika prikazuje i jezike koji egzistiraju u sklopu semantičkog weba. Struktura semantičkog weba nije zamišljena kao zamjena za klasični web, već kao njegova nadopuna. Bitno je naglasiti da se paralelno uz razvoj računarstva razvijaju i slojevi semantičkog weba, te da svaka komponenta strukture

⁹ *WWW konzorcij, W3 konzorcij, W3C - svjetski konzorcij koji je zadužen za standardizaciju Weba*

osim funkcionalnosti u sebi nosi i potencijalne nedostatke na čijim se rješenjima radi iz dana u dan.



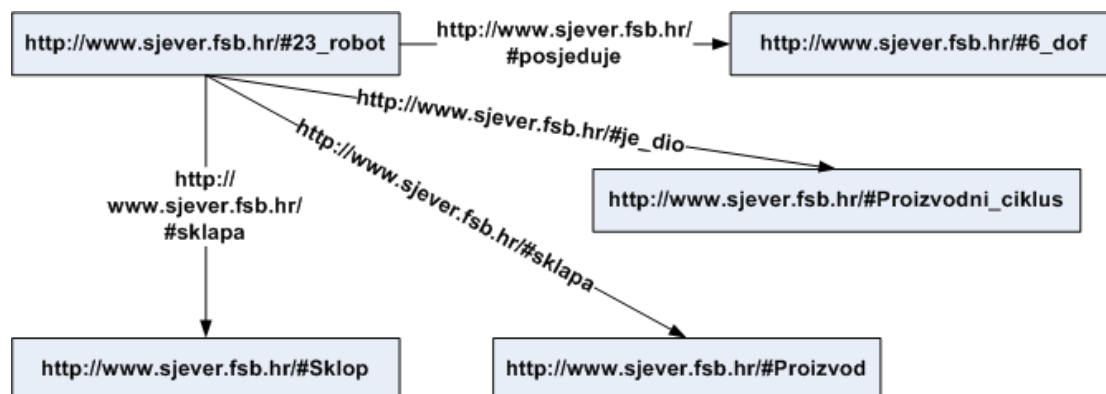
Slika 3-2. Slojevi (stog) semantičkog weba s pripadajućim tehnologijama.

Na dnu prikazane strukture slojeva nalaze se *Unicode* i *URI* (engl. *Uniform Resource Information*) sloj. Osim što se brine da korisnici uvijek koriste međunarodno definirani postav znakova, taj sloj pomaže prilikom identificiranja objekata unutar semantičkog web-a te predstavlja njegove temelje.

U sloju *XML* (engl. *Extensible Markup Language*) je definiran osnovni *XML* jezik koji omogućuje pisanje strukturiranih web dokumenata pomoću rječnika definiranog od strane korisnika. *XML* je posebno pogodan za razmjenu i dijeljenje dokumenata preko weba.

RDF (engl. *Resource Description Framework*) je osnovni podatkovni model za pisanje jednostavnih izjava o web objektima (resursima). Iako koristi sintaksu temeljenu na *XML-u*, ovaj model ne ovisi o njemu. Stoga je *RDF* smješten odmah iznad *XML* sloja. *RDF* podatke sprema u, tzv. trojke (engl. *triples*) koristeći *subjekt (S)*, *predikat (P)*, *objekt (O)* notaciju

preuzetu iz elementarne gramatike. Slika [Slika 3-3] prikazuje subjekt koji čini trojke s četiri objekta preko pripadajućih predikata.



Slika 3-3. Primjer RDF grafa.

Trojke sa slike tumače se na sljedeći način:

- Robot (*S*) sklapa (*P*) Sklop (*O*),
- Robot (*S*) sklapa (*P*) Proizvod (*O*),
- Robot (*S*) je dio (*P*) Proizvodnog ciklusa (*O*),
- Robot (*S*) posjeduje (*P*) 6 *DOF* (*O*).

Kao što je moguće vidjeti, svi članovi trojki (subjekti, predikati i objekti) posjeduju svoje jedinstvene adrese definirane pomoću *URI-a*.

RDFS (*RDFSchema*) predstavlja osnovni alat prilikom oblikovanja hijerarhijske strukture web objekata. Ključni mehanizmi oblikovanja kod *RDFS-a* su: odnosi klasa (engl. *classes*) i svojstva (engl. *properties*), odnosi podklasa (engl. *subclasses*) i podsvojstava (engl. *subproperties*) te restrikcije domena (engl. *domains*) i raspona (engl. *ranges*). Budući da posjeduje navedene mehanizme, *RDFS* je moguće promatrati kroz prizmu jednostavnog jezika za pisanje ontologija. Ipak, da bi bilo moguće opisivati kompleksnije odnose između web objekata, danas se koristi zaključivanje temeljeno na logici što je glavna karakteristika *OWL-a* (engl. *Ontology Web Language*). Za razliku od *RDFS-a*, *OWL* posjeduje veći broj operatora (npr. presjeke, unije i negacije) čime je omogućeno opisivanje složenijih koncepata. Budući da je korišten prilikom izrade ontologije koja opisuje domenu problema ovog rada, jedno od sljedećih poglavlja razrađuje *OWL* puno detaljnije.

Na istom sloju stoga semantičkog weba nalazi se *SPARQL* jezik za postavljanje upita, te *RIF* i *SWRL* jezici temeljeni na logičkim pravilima. Pomoću *SPARQL-a* je moguće postavljati upite bazama znanja koje su pisane nekim od ranije spomenutih jezika. Ovaj jezik se može usporediti s *SQL* jezikom koji se koristi prilikom postavljanja upita kod običnih relacijskih

baza podataka. Za razliku od *SQL-a*, *SPARQL* ne podržava mijenjanje, brisanje ili ubacivanje podataka već samo njihovo izlistavanje prema zadanim kriterijima.

```
PREFIX p: <http://movies.org/#>
SELECT ?movie ?director
WHERE {
    p:AlPachino p:playedIn ?movie .
    ?movie p:directedBy ?director .
}
```

Slika 3-4. Primjer SPARQL upita.

Pomoću *SPARQL-a* moguće je kreirati kompleksnije upite koji u sebi sadrže logičke izraze što omogućuje da se dio zaključivanja izvede na taj način. Slika [Slika 3-4] prikazuje sintaksu *SPARQL* upita bazi koji potražuje izlist svih filmova u kojima je glumio Al Pachino. Zaključivanje pomoću *SPARQL* upita može smanjiti vrijeme procesiranja odgovora od strane baze znanja. Sljedeća prednost je svakako mogućnost smanjenja kompleksnosti same ontologije, budući da se logičke rečenice definiraju u samom *SPARQL* upitu. *SPARQL* upiti koriste se primarno s *RDF* i *RDFS* jezicima budući da ne podržavaju u potpunosti *OWL*. Osim zbog otežanog rada sa *SPARQL* jezikom, prekompleksno modelirana ontologija nije poželjna niti iz drugih razloga, od kojih su neki: otežano povezivanje s ostalim ontologijama koje opisuju istu ili sličnu domenu djelovanja (mapiranje), otežano tumačenje, odnosno shvaćanje ontologije od strane osoba koje nisu bile direktno uključene u njen razvoj i sl. Navedeni razlozi mogu potpuno onemogućiti primjenu takve ontologije u stvarnim aplikacijama. Zbog toga je za primjene koje se izvode u realnom vremenu prilikom razvoja ontologije najbolje tražiti kompromisna rješenja tako da se jedan dio zaključivanja izvodi unutar ontologije, a drugi uz pomoć *SPARQL* upita.

U slučajevima kada postoji potreba za dodatnom ekspresivnošću prilikom opisivanja domene djelovanja koju nije moguće postići samo pomoću deskriptivne logike, koriste se pravila (engl. *Rules*). Danas postoji velik broj programskih jezika temeljenih na pravilima (npr. logičko programiranje – *Prolog*, produkcijska pravila i sl.). Programski jezici predstavnici pravila razvijeni za uporabu u sklopu semantičkog weba su *RIF* (engl. *Rule Interchange Format*) [58] i *SWRL* (engl. *Semantic Web Rule Language*) [59], koji je u praksi puno korišteniji. *RIF* je razvijen s idejom da web aplikacije mogu međusobno razmjenjivati pravila omogućujući pritom međusobno razumijevanje različito definiranih pravila na različitim sustavima. *SWRL* svoju popularnost u prvom redu zaslužuje zbog podrške softvera

za izradu ontologija i to zato što je temeljen na općeprihvaćenim i uvriježenim *OWL-DL* (derivat *OWL-a* koji podržava deskriptivnu logiku) i *RuleML* (engl. *Rule Markup Language*) jezicima.

Slojevi na vrhu pripadaju slojevima budućnosti. Na njima se danas jako puno radi te oni u prvom redu egzistiraju više u laboratorijima, a manje unutar primjena u sklopu realnih aplikacija. Oni objedinjuju i poboljšavaju mehanizme zaključivanja temeljene na deskriptivnoj logici i pravilima (sloj objedinjena logika), te sigurnost vezanu za razmjenu, prikaz i autentifikaciju (slojevi sigurnost, kriptografija i povjerenje).

Posljednji sloj koji i nije pravi sloj predstavlja korisničko sučelje i aplikaciju koja objedinjuje sve prethodne slojeve.

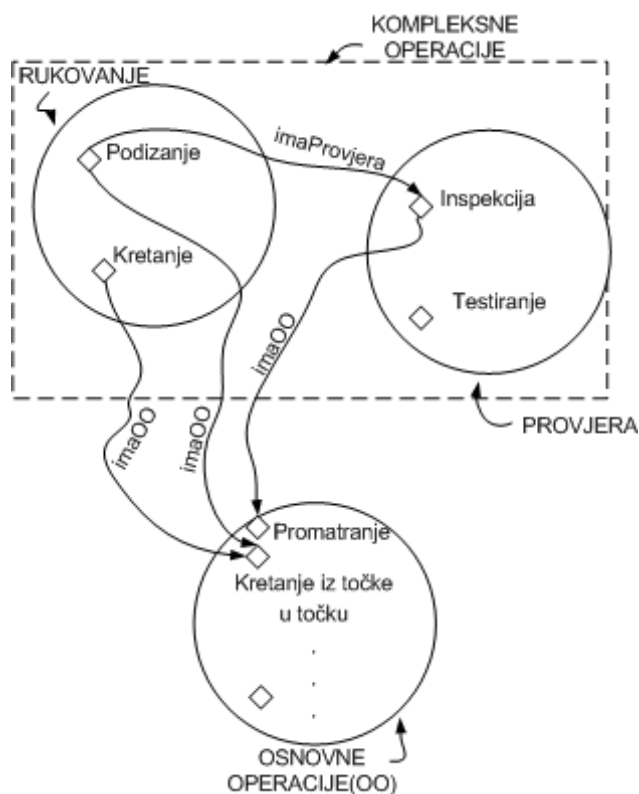
3.2. Ontologije

Još od vremena Aristotela [60], filozofi istražuju načine kako opisati ono što postoji. Ontologija kao temeljna disciplina metafizike proučava biće (subjekt) kao takvo, zajedno s vezama i odnosima koje to biće ima u svijetu koji nas okružuje. U trenutku kada smo svjesni da nešto postoji, prirodno je zapitati se o pripadnostima i vezama s već postojećim. Ontologija propituje samu bit bića, njegovo postojanje (egzistenciju), stvarnost te pripadajuće kategorije [61]. Na sličan način, ontologije se koriste i kod računalnih znanosti: kao alat za stvaranje modela te pohranu znanja o svijetu koji nas okružuje. Navedeni modeli se potom koriste u prilikom različitih namjena, i to kao dio, npr. semantičkog weba, aplikacija svjesnih konteksta, baza znanja i sl. U literature postoje različite definicije ontologija. Među najpoznatijima i najprihvatljivijima je svakako ona navedena u [62], koja ontologiju definira kao:

formalnu reprezentaciju entiteta (subjekata, klasa) unutar domene od interesa, zajedno s pripadajućim atributima (objektima) i njihovim međusobnim odnosima (relacijama, vezama).

Ontologija osigurava precizan rječnik koji može biti korišten prilikom predstavljanja znanja. Predstavljanje znanja podrazumijeva formalizaciju sakupljenog znanja u obliku u kojem je ono pogodno za uporabu. Uz odabir entiteta koji će biti predstavljeni, ontologija omogućuje njihovo grupiranje te definiranje odnosa koji ih međusobno povezuju. Što je ontologija detaljnija, domena koju opisuje je bolje definirana. Ipak, u slučaju da je ontologija predetaljna može postati prekompleksna za korištenje, održavanje i/ili proširivanje.

Ontologija je sastavljena od taksonomije koja prikazuje strukturu informacija te logike koja se koristi prilikom zaključivanja. Taksonomija uključuje, najčešće hijerarhijski prikaz entiteta (klasa, subjekata), objekata (individua) i pripadajućih svojstava (relacija).



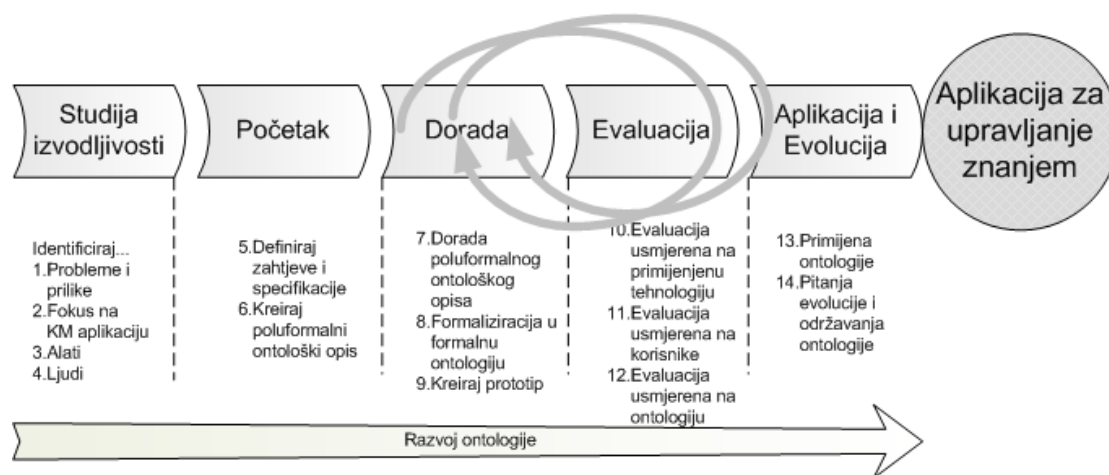
Slika 3-5. Klase, objekti i svojstva.

Slika [Slika 3-5] prikazuje klase, objekte zajedno sa pripadajućim svojstvima koja ih povezuju. Tako je objekt *Podizanje* koji pripada klasi *RUKOVANJE* preko svojstva *imaProvjera* povezan s objektom *Inspekcija* koji pripada klasi *PROVJERA*. Na ovome primjeru moguće je objasniti koncepte kao što su domena (engl. *Domain*) i dosezi (engl. *Ranges*) koji su proizašli iz *RDFS-a*. U ovome slučaju, domena u kojoj se objekt *Podizanje* nalazi je klasa *RUKOVANJE*, a doseg je klasa *PROVJERA*.

Hijerarhijska struktura uključuje pojmove podklasa i nadklasa. Klase i objekti su najčešće pripadnici neke od unaprijed definiranih (engl. *asserted*) ili zaključenih (engl. *inferred*) klasa. Logika ontologijama omogućava izvođenje zaključaka na temelju postojeće taksonomije i postavljenih pravila. Tako je moguće koristeći deskriptivnu logiku, koja predstavlja sastavni dio ontologija na Internetu, zaključivanjem stvarati nove klase.

Prilikom čitanja ontologije, softveru trebaju biti dostupne sve informacije (činjenična znanja, odnosno dokazi o stanju u okolini) kako bi mogao donjeti zaključke po uzoru na čovjeka.

Zadnjih godina razvijen je i predstavljen veći broj jezika za definiranje ontologija. Među najznačajnijim jezicima su: format za razmjenu znanja (engl. *Knowledge Interchange Format – KIF*, [63]), *Ontolingua* [64], *CommonKADS CML* [65], *CycL* [66], *DAML + OIL* [67] i *OWL*. Zadnji navedeni i najkasnije razvijeni jezik *OWL* je svakako onaj koji trenutno najviše obećaje. Ovaj ontološki jezik se prvenstveno koristi na webu te je razvijen od strane *W3* konzorcija. Temelji se na *XML* i *RDF* reprezentacijskim jezicima koji su opisani u prethodnom poglavlju.



Slika 3-6. Meta-proces razvoja ontologija.

Slika [Slika 3-6] prikazuje meta-proces razvoja znanja koji je izvorno opisan u [68]. Prema literaturi, meta-proces razvoja znanja se sastoji od pet glavnih koraka. Svaki korak u sebi sadrži veći broj podkoraka te u konačnici rezultira određenim stupnjem razvoja. Krajnji cilj je razvijena ontologija koja predstavlja znanje o ciljanoj domeni. Prilikom kreiranja ontologije za potrebe ovog rada korištena je ista metodologija.

Sustavi za upravljanje znanjem mogu funkcionirati efikasno jedino ako su zadovoljavajuće integrirani unutar sustava na globalnoj razini. Da bi se osigurala njihova zadovoljavajuća integracija, prije kreiranja ontologije potrebno je načiniti, tzv. **analizu izvodljivosti** (engl. *Feasibility Study*). Ona se provodi s ciljem identificiranja potencijalnih “slabih točaka” te njihovih mogućih rješenja. Time postupak kreiranja ontologija može biti uvelike olakšan budući da dizajner na početku razvoja ontologije na raspolaganju ima više informacija koje mu omogućuju optimalan razvoj u ovisnosti o područjima primjene. Postavlja se pitanje, po kojim kriterijima evaluirati ontologiju da bi ona dala optimalne rezultate? U sklopu disertacije naglasak je stavljen na sustavu postavljene zahtjeve glede dostupne opreme te specifičnosti okoline i sklapanih objekata. Ako je ontološka baza modela dovoljno detaljno i robusno definirana, razvijeni model će biti moguće upotrijebiti u različitim slučajevima robotskog sklapanja. Analiza izvodljivosti može dizajneru sugerirati kako kreiranom ontologijom postići

različite ciljeve, npr. ekonomske, tehničke, projektne i sl. Kod provođenja analize izvodljivosti prilikom izrade ontologije za potrebe ovog rada, uzeta je u obzir samo tehnička komponenta. Generalno, analiza mora sadržavati odgovore na pitanja kao što su: identifikacija mogućih problema, određivanje prikladnih parametara koji osiguravaju rad sustava u skladu s potrebama aplikacije, odabir primjerenih alata i stručnjaka iz područja za koje se izrađuje ontologija (engl. *domain experts*) i sl.

Prema navedenom meta-procesu **početna faza** (engl. *Kickoff*) predstavlja stvarni početak razvoja ontologije. Ona uključuje definiranje zahtjeva i specifikacije te kreiranje poluformalnog ontološkog modela. Definirani zahtjevi i specifikacije dizajneru olakšavaju razvoj inicijalne hijerarhijske strukture (taksonomije) koja uključuje klase, pripadajuće objekte te njihove međusobne odnose. Klase, podklase i objekti se kreiraju u skladu s definiranim zahtjevima i specifikacijama. Ovaj korak uključuje pronalazak i analizu do sada napravljenih ontologija. Također, u sklopu ovog koraka moguće je analizirati različite rječnike ili tekstualne dokumente koji sadržavaju određeno znanje o ciljanoj domeni. Rezultat ove faze predstavlja poluformalni ontološki model, najčešće prikazan grafikonom koji uključuje hijerarhijski povezane čvorove (klase, objekte). Poveznice predstavljaju neimenovane linije koje će u sljedećoj fazi sadržavati opisni tekst. U slučaju da poluformalni model u zadovoljavajućoj mjeri opisuje tražene zahtjeve i specifikacije, razvoj ontologije može prijeći u sljedeću fazu. Odluku o prelasku donose zajedno dizajner ontologije i stručnjak iz područja koje ontologija treba predstavljati u budućnosti. Kako je proces razvoja ontologije kružni, nije nemoguće da se iz neke kasnije faze vrati opet na početak.

Sljedeća faza u razvoju ontologije naziva se **faza dorade** (engl. *Refinement*) te uključuje nastavak razvoja poluformalne ontologije nastale u prethodnoj fazi. Konzultiraju se dodatni podaci iz dostupne izvora koji pobliže opisuju domenu interesa i to koristeći jedan od dva pristupa: *odozgo-prema-dolje* (engl. *top-down*) ili *odozdo-prema-gore* (engl. *bottom-up*). Glavna karakteristika prvog pristupa je kreiranje koncepata i odnosa na generalnoj razini koji se potom doraduju. Ovaj pristup se najčešće radi ručno i često vodi do ontologija vrlo visoke kvalitete koje vjerno opisuju ciljanu domenu. Pristup *odozdo-prema-gore* se najčešće koristi prilikom razvoja ontologija koristeći već gotove rječnike, koji sadrže pojmove karakteristične za domenu interesa, zajedno s programskom podrškom za automatsku analizu dokumenata. Iako ovaj pristup može rezultirati s manje vjernim ontološkim opisom, upotrebljava se u slučajevima kada su ontologije veće i/ili kompleksnije. Poluformalni ontološki opis najčešće sadržava samo veze tipa *is-a* i *has-a*. Navedeni tipovi veza se koriste kod: aplikacija za predstavljanje znanja, objektno-orijentiranog programiranja ili dizajniranja općenito.

Predstavljaju one odnose u kojima je jedna klasa pripadnik neke druge klase (*is-a*), odnosno one odnose u kojima neka klasa pripada nekoj drugoj klasi (*has-a*) [69]. Prilikom razvoja ontologije koja je nastala u sklopu ovog rada korišten je pristup *odozgo-prema-dolje* što je rezultiralo ontologijom koja relativno uspješno i precizno opisuje znanje o domeni od interesa. Postupak formalizacije poluformalne u ciljanu ontologiju započinje doradom postojeće taksonomije te dodavanjem pripadajućih odnosa (veza) koji ne uključuju samo informacije o odnosima podklasa i nadklasa. Rezultat ove faze je “ciljana ontologija” koja je spremna za evaluaciju u sljedećem koraku. Glavni mehanizam provjere rezultata ove faze predstavlja usporedba da li ciljana ontologija odgovara zahtjevima i specifikacijama iz prve faze.

Prema meta-procesu razvoja ontologija, faza **evaluacije** (engl. *Evaluation*) može uključivati tri različita pristupa: (1) evaluacija usmjerena na tehnologiju, (2) evaluacija usmjerena na korisnike i (3) evaluacija usmjerena na ontologiju. U pristupu gdje se evaluacija provodi respektirajući korištenu tehnologiju važno je da odabrana tehnologija osigura karakteristike kao što su izražajnost, skalabilnost, interoperabilnost, dosljednost i sl. To će omogućiti dizajneru da razvije ontologiju koja je u skladu sa potrebama aplikacije koristeći odabrane alate. Kod evaluacije usmjerene na korisnike provode se ispitivanja koja daju odgovore daje li ontologija odzive koji su u skladu s očekivanjima korisnika. Pogrešno definirane logički odnosi mogu rezultirati s pogrešnim rješenjima koja predstavljaju odziv na zadane ulazne parametre. Stoga, posljednji pristup evaluaciji sadržava analizu razvijene ontologije na način da se provjerava dosljednost (konzistencija) logičkih odnosa definiranih u taksonomiji. Rezultat ove faze predstavlja “evaluirana ontologija” spremna za integraciju. Važno je naglasiti da ova faza također može proći kroz nekoliko iteracija “evaluacija-dorada-evaluacija” rutina sve dok osoba(e) koja(e) razvijaju ontologiju ne procijene da je sve spremno za sljedeći korak.

Faza **aplikacije i evolucije** (engl. *Application and Evolution*) uključuje: (1) integraciju razvijene ontologije na globalnoj razini (razina aplikacije), te (2) osiguravanje daljnjih poboljšavanja (evoluciju) u skladu s iskustvima stečenim prilikom korištenja ontologije u praksi. Rezultat ove faze je, tzv. evoluirana ontologija koja predstavlja novu, odnosno nadopunjenu verziju ontologije proizašle iz prethodne faze. Na kraju ove faze dobro je uzeti u obzir potrebu za novim ciklusom koji će omogućiti postojećoj evoluiranoj ontologiji novi evolucijski ciklus.

3.3. Zaključivanje zasnovano na deskriptivnoj logici

Deskriptivna logika (*DL*, engl. *Descriptive Logic*) razvila se kao ekstenzija semantičkih mreža, okvira i logike. Možemo reći da je to inteligentna aplikacija koja zaključivanjem stvara novo znanje iz već postojećeg. Namijenjena je terminološkom semantičkom opisu neke domene u sklopu koje se izvodi zaključivanje. Danas čini okosnicu ideje semantičkog weba i koristi se u izračunu računalnih ontologija. Deskriptivna logika je skupina jezika, a ne samo jedan jezik. Većinu opisne logike čine odlučljivi formalizmi koji su podskup logike prvog reda. Deskriptivna logika pruža samo jedan način oblikovanja ontologije, dok je ontologija općenitiji pojam.

Deskriptivna logika se fokusira na predstavljanje onoga što nazivamo terminološko znanje ili konceptualno znanje, ona opisuje dio našeg svijeta ne podrazumijevajući da zna sve o njemu. Ona operira nad konačnom domenom, ima samo unarne i binarne predikate i nema eksplicitne varijable.

Cilj deskriptivne logike je formalizirati osnovnu terminologiju modelirane domene, pohraniti je u ontologiju i omogućiti zaključivanje temeljem tog znanja.

Prema paradigmi u kojoj je znanje o domeni primjene izdvojeno u zasebni podsustav, osnovu "inteligentnog" ponašanja čine entiteti i relacije tog podsustava. Znanje u tom podsustavu mora biti tako organizirano da je na temelju njega moguće zaključivanje (engl. *reasoning*), tj. izvođenje informacija koje nisu eksplicitno prisutne. Tek uz mogućnost zaključivanja skup podataka postaje znanje, a programska podrška postaje "inteligentna". Iako danas postoji velik broj različitih pristupa predstavljanju znanja, moguće je nabrojati 5 glavnih paradigmi:

1. Matematička logika,
2. Okviri,
3. Pravila,
4. Konceptualne, Semantičke mreže i
5. Umjetne neuronske mreže.

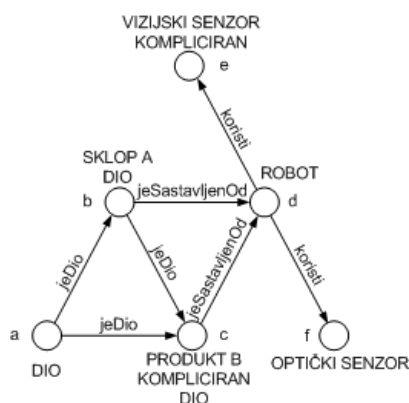
Svaki od ovih pogleda dolazi iz različitih izvora. Tako npr., okviri i semantičke mreže imaju temelje u psihologiji, umjetne neuronske mreže u neurologiji, a matematička logika u logici. Različite paradigme na različite načine pristupaju znanju, njegovom sadržaju i postupcima zaključivanja. Deskriptivne ili opisne logike (eng. *descriptive logics*) su formalni jezici za predstavljanje znanja utemeljeni na matematičkoj logici. Naziv "opisne logike" dolazi iz činjenica da se pojmovi iz neke domene nazivaju "opis koncepta" i semantika izraza

koji se pojavljuju je utemeljena na logici. Opisne logike su poslužile kao teoretska osnova za razne sustave i implementacije predstavljanja znanja. Najpoznatija i najraširenija implementacija je u sklopu *OWL-a*. Sustavi utemeljeni na deskriptivnoj logici modeliraju različite domene primjene. Tako npr., domena primjene može biti medicinska dijagnostika, taksonomija životinja ili programsko inženjerstvo. U deskriptivnim logikama, kao i u ostalim inačicama matematičke logike, za prikaz objekata iz domene primjene koristimo skup imena. Imena u *DL* predstavljaju pojedine objekte, skupove objekata i relacije između objekata domene primjene. Preslikavanje između imena i objekata naziva se interpretacija jer nam govori kako treba interpretirati imena koje koristimo. Interpretacija uspostavlja korespondenciju između imena i stvarnih objekata u nekoj domeni. Domena primjene naziva se još i interpretacijska domena radi toga što je povezana s interpretacijom koja se koristi.

Simboli deskriptivne logike su vrlo slični simbolima koji se koriste u ostalim logikama. Ovdje su navedeni operatori koji se koriste te koje im je značenje: Skup svih individua (\mathbb{T}), prazan skup (\perp), negacija i komplement (\neg), konjunkcija i presjek (\cap), univerzalni kvantifikator (\forall), egzistencijalni kvantifikator (\exists), disjunkcija i unija (\cup) inkluzija koncepata (\subseteq), definiranje koncepta (\doteq), ekvivalencija koncepata (\equiv), te pripadnost konceptu, odnosno ulozu (\cdot).

Semantika deskriptivne logike je bazirana na interpretaciji. Interpretacija u deskriptivnoj logici predstavlja potpunu sliku, odnosno opis svijeta, kako je prikazano u primjeru na [Slika 3-7]. Formalno, semantika je osnovana na uređenom paru (Δ^I, \cdot^I) , gde je:

- Δ^I : domena interpretacije I ,
- \cdot^I : interpretacijska funkcija koja preslikava svako ime, tzv. atomičkog koncepta A u podskup, A^I od Δ^I i svako ime uloge R u binarnoj relaciji R^I nad Δ^I .



Slika 3-7. Primjer jedne interpretacije.

Tablica 3-1. Interpretacija koncepata iz primjera sa [Slika 3-7].

Atomički koncept (A)	Skup u koji se preslikava A^I
<i>DIO</i>	$\{a, b, c\}$
<i>SKLOP A</i>	$\{b\}$
<i>PRODUKT B</i>	$\{c\}$
<i>KOMPLICIRAN</i>	$\{c, e\}$
<i>OPTIČKI SENZOR</i>	$\{f\}$
<i>ROBOT</i>	$\{d\}$
<i>VIZIJSKI SENZOR</i>	$\{e\}$

U prikazanom primjeru interpretacije je definirana skupom Δ^I koji sadrži elemente $\{a, b, c, d, e, f\}$, te preslikavanjem koje atomičkim konceptima A pridjeljuje skupove A^I , a ulogama (svojstvima) R pridjeljuje skupove R^I , kako je prikazano u tablicama [Tablica 3-1, Tablica 3-2].

Tablica 3-2. Interpretacija svojstava iz primjera sa [Slika 3-7].

Svojstva (R)	Skup u koji se preslikava R^I
<i>jeDio</i>	$\{(a, b), (a, c), (b, c)\}$
<i>jeSastavljenOd</i>	$\{(b, d), (c, d)\}$
<i>koristi</i>	$\{(d, e), (d, f)\}$

Budući da je interpretacija po definiciji potpuno slika svijeta, odnosno domene od interesa, ono što nije navedeno u interpretaciji sigurno nije istinito (npr. individua e nije optički senzor jer ne pripada skupu *OPTIČKI SENZOR*^I). Navedenu metodologiju je moguće koristiti prilikom kreiranja složenijih izraza koji definiraju različite klase unutar interpretacije proizašle iz relacija koje su definirane ranije navedenim logičkim simbolima.

3.4. OWL – ontološki jezik za primjenu na webu

Ontologije koristimo prilikom pohrane znanja o nekoj domeni djelovanja. Pomoću njih je moguće opisivati koncepte unutar domene zajedno s njihovim pripadajućim odnosima. *OWL* (engl. *Ontology Web Language*) je ontološki jezik razvijen kao sljedbenik iz *RDF* i *RDFS-a*, a baziran na formalnoj semantici *XML-a*. Formalnu osnovu za definiciju *OWL-a* daje deskriptivna logika. Resursi koji su definirani koristeći *RDF* i *RDFS* se mogu detaljnije specificirati koristeći *OWL* jezične konstrukte koji su preuzeti iz deskriptivne logike. *OWL* je standardni predviđen za korištenje na webu za opisivanje ontologija nastao kao evolucija jezika *OIL*, *DAML* i *OIL+DAML*. Sintaksno gledano, *OWL* je dodatni rječnik koji se koristi u *RDF* izjavama. *OWL* jezik, slično kao i *RDFS*, omogućava definiranje tipova resursa, njihovih svojstava i veza. U odnosu na *RDFS*, *OWL* dodatno omogućuje: definiranje karakteristika svojstava, ograničavanje vrijednosti svojstva putem tipova resursa,

ograničavanje broja pojavljivanja svojstva, izražavanje jednakosti svojstava, definiranje novih tipova resursa operacijama nad skupovima postojećih resursa, nabranjem resursa, istovjetnošću te razlikom tipova resursa. *OWL* definira i nekoliko predikata za izražavanje jednakosti i/ili različitosti pojedinih resursa, te definira način dohvata *OWL-om* izražene ontologije. Rezultat dodatnih mogućnosti *OWL-a* jest mogućnost gradnje detaljnijih ontologija. Detaljnije ontologije bolje karakteriziraju svojstva resursa, tipove resursa i veze među resursima, što pospješuje postupke zaključivanja računalnih agenata koji koriste ontologiju. Informacije opisane *OWL-om* postaju znanje, a ne više skup podataka. Kada se *OWL-u* pridoda i mogućnost izvođenja činjenica koje nisu eksplicitno navedene, informacije stvarno postaju znanje, a *OWL* postaje jezik za predstavljanje znanja. *OWL* uvodi skup jezičnih oznaka, u kojem su najznačajniji konstrukti za uniju i presjek klasa (ili svojstava), konstrukti za definiranje kardinaliteta (dozvoljen broj instanci u pojedinoj klasi) te konstrukti koji označavaju logičke kvantifikatore (*allValuesFrom* i *someValuesFrom*). Predviđene su tri mogućnosti korištenja *OWL* ontologija.

Ontologija definirana pomoću *OWL-a* sastavljena je od klasa (engl. *Classes*), objekata ili individua (engl. *Individuals*, *Objects*) te svojstava (engl. *Properties*). Omogućuje korištenje većeg broja operatora, npr. presjeka, unija i negacija. Logički model sadržava, tzv. mehanizme za automatsko zaključivanje (engl. *Reasoners*) pomoću kojih je moguće provjeravati daje li ontologija rezultate u skladu s očekivanjima.

Individue (ili instance klasa) predstavljaju objekte unutar domene od interesa. Individue su osnovana, početna razina sastavnica ontologije. Individue u ontologiji mogu uključiti konkretne objekte poput ljudi, životinja, molekula, planeta, kao i apstraktne individue poput brojeva i riječi. Ontologija ne mora uključiti individuu, no jedna od općih svrha ontologije jest omogućavanje sredstava za klasifikaciju individua pa i ako te individue nisu dio same ontologije. Karakterizira ih to da ne predstavljaju klasu, odnosno ne mogu unutar svoje definicije sadržavati još sastavnica. Individua jedino može biti pripadnik neke druge (ili drugih) klasa.

Svojstva se mogu shvatiti kao veze između individua te predstavljaju, tzv. binarne¹⁰ odnose. Koristeći svojstva, odnosno povezujući objekte koji pripadaju različitim klasama moguće je stvarati nove (zaključene) klase. Svojstva su naslijeđiva iz klase u podklasu, što znači da će neka klasa imati obilježja, odnosno svojstva svoje superklase. Postoje različiti tipovi svojstava koje klasa može imati. Ne postoji ograničenje broja svojstava koje neka klasa

¹⁰ Binarni odnos je definiran kao odnos između dvije individue (između dva pojma, objekta, stvari i sl.).

može imati niti ograničenje broja klasa koje se pomoću nekog svojstva mogu povezati s odabranom klasom. Postoje različiti tipovi svojstava te je pri kreiranju novog svojstva potrebno odabrati određeni tip.

Unutar ontologije razlikuju se dvije vrste znanja: opće ili terminološko znanje (engl. *Terminology Box, TBox*), te utvrđeno znanje (engl. *Assertion Box, ABox*). *TBox* znanje opisuje koncepte i njihove međusobne odnose, dok se *ABox* odnosi na opisivanje pripadnosti individua određenim konceptima, kao i dodjeljivanjem uloga individuama. Primjer *TBox* aksioma bi bio $C \sqsubseteq D$, što označava da koncept D uključuje koncept C . Primjer *ABox* aksioma koji označava pripadnost individue a konceptu C jest $C(a)$, dok se povezivanje individua a i b ulogom r označava s $r(a,b)$.

4. ROBOTIKA ZASNOVANA NA PROBABILISTIČKIM METODAMA

“

So far as the laws of mathematics refer to reality they are not certain. And so far as they are certain they do not refer to reality.

”

Albert Einstein

4.1. Probabilistika kao dio umjetne inteligencije

Među mnogobrojnim definicijama koje su fokusirane na različita filozofska i praktična pitanja, kao što su:

- Je li inteligencija jedan pojam ili nešto što objedinjuje različite pojmove koji ne moraju biti međusobno povezani?
- Kako je inteligencija povezana s učenjem ili ranije stečenim iskustvom?
- Što su znanje i (samo)svijest te kako su ostvareni i kroz inteligenciju?
- ...,


sljedeća definicija je izdvojena kao posebno prikladna za ovu disertaciju budući da naglašava teoretske osnove te primjenu alata, tehnika i algoritama korištenih prilikom predstavljanja znanja. Dakle,

umjetnu inteligenciju je moguće definirati kao polje računalnih znanosti koje je povezano s modeliranjem automatiziranog inteligentnog ponašanja [70].

Budući da postoji jako puno različitih interpretacija onoga što umjetna inteligencija jest, radu je priloženo još nekoliko odabranih, te u literaturi citiranih definicija:

- *Umjetna inteligencija je novo i uzbudljivo nastojanje s ciljem da se računala nauče misliti ... strojevi s mislima, u potpunom i literalnom smislu [71].*
- *Istraživanje mentalnih sposobnosti kroz korištenje matematičkih modela [72].*
- *Umjetnost izrade strojeva koji izvršavaju funkcije koje su inteligentne u slučaju da ih izvode ljudi [73].*
- *Računalna inteligencija se bavi dizajnom inteligentnih agenata [74].*

Automatizirano zaključivanje (engl. *automated reasoning*) je područje umjetne inteligencije koje uključuje računalne znanosti i matematičku logiku te proučava različite aspekte razumijevanja. Interes znanstvenika za metodologiju automatiziranog zaključivanja seže skroz na početke razvoja umjetne inteligencije kada su činjeni veliki napori prilikom razvoja računalnih algoritama za rješavanje problema koji zahtijevaju određeni stupanj računalne inteligencije. Alati i tehnologije automatskog razumijevanja mogu se temeljiti na klasičnoj te neizrazitoj (engl. *fuzzy*) logici [75], Bayesovom zaključivanju [76], zaključivanju s maksimalnom entropijom [77] i sl. Dakle, automatizirano zaključivanje može biti temeljeno na nesigurnostima (probabilistici) ili na logici koja svoje zaključke temelji na unaprijed determiniranoj domeni od interesa. Kao što je slučaj s modelom razvijenim u sklopu ovog rada, te dvije metodologije mogu nadopunjavati jedna drugu tvoreći pritom hibridni sustav. John McCarthy [78], američki znanstvenik i pionir umjetne inteligencije, 1959. godine predložio je generalnu preporuku za dizajniranje sustava koji koriste metodologiju automatiziranog zaključivanja [Slika 4-1].



Slika 4-1. Sustav za zaključivanje temeljen na logici.

Za razliku od logičkog zaključivanja koje je djelomično opisano u trećem poglavlju disertacije, zaključivanje temeljeno na nesigurnostima svoju snagu pronalazi iz ranije stečenog – ugrađenog znanja koje je najčešće nepotpuno, te iz vjerovanja temeljenog na trenutno prepoznatim okolnostima, odnosno dokazima. Upravo zaključivanje temeljeno na nesigurnostima predstavlja dio metodologije razvijene za upravljanje robotom u grupi u sklopu primijene opisane u ovom radu. Unutar *UI* zajednice (engl. *Artificial Intelligence Community*) prepoznata su barem tri različita oblika nesigurnosti koje bi inteligentni sustavi smješteni u okolini trebali rješavati [79]:

- Neznanje – ograničenja našeg znanja vode nas ka nesigurnostima.
- Fizička slučajnost ili nedeterminizam – realni svijet nije moguće potpuno odrediti ako promatramo skalu iznad veličine atoma. To znači da živimo u determinističkom kaosu gdje je nemoguće predvidjeti sve mogućnosti i potrebe za djelovanjem promatranog sustava u realnoj okolini.


- Nedorečenost – često nije jasno koliko točno je potrebno klasificirati neku klasu objekata od interesa. Tada se u realnim primjenama može dogoditi nedorečenost, odnosno nedovoljna detaljnost prilikom semantičkog opisa domene interesa (npr. je li čovjek koji je objekt unutar istoimene klase hrabar ili kukavica).

Bajesianizam (engl. *Bayesianism*) je dio filozofije koji podrazumijeva da se ljudsko mišljenje treba gledati upravo kroz prizmu neznanja i nesigurnosti. Bayesianisti smatraju da probablistika predstavlja najvažniji matematički alat kojim se može izraziti vjerovanje (ljudsko ili umjetne tvorevine). Prateći spomenuto filozofsko razmatranje te koristeći probablistiku (zaključivanje temeljeno na Bayesovoj mreži) ostvarenu unutar razvijenog spoznajnog modela, robot unutar grupe je sposoban donositi odluke procjenjujući za grupu najbolja rješenja. Formalizam Bayesovih mreža je izmišljen da bi omogućio efektivno predstavljanje i zaključivanje koristeći nepotpuno definirano znanje [80].

Svakako, jedan od zanimljivijih ciljeva vezanih za uporabu metodologije umjetne inteligencije je njena primjena na realnim sustavima. Probablistička robotika je dio robotike u kojem se poseban naglasak postavlja na percepciju i kontrolu. Ona se oslanja na probablističke tehnike prilikom predstavljanja informacija te donošenja odluka. Svoju snagu crpi iz nesigurnosti koje proizlaze iz suvremenih robotskih primjena. Posljednjih godina, tehnike koje koriste probablistiku postaju dominantni izvor inspiracija prilikom razvoja algoritama, tj. upravljačkih programa u robotici.

4.2. Teorijske osnove

Račun vjerojatnosti omogućuje nam predstavljanje, odnosno prikazivanje ovisnosti unutar različitih domena interesa. Izmišljen je u 17. stoljeću prilikom analiziranja problema vezanih za nesigurnosti kod kockanja (*Fermat i Pascal*).



Slika 4-2. Venn-ovi dijagrami: Prostor događaja U .

Nije trebalo dugo da navedeni koncepti budu prepoznati kao nešto generalno (*Butler*, 18. stoljeće). Venn-ovi dijagrami sa slike [Slika 4-2] predstavljaju jednostavan i učinkovit način za predstavljanje formalnog jezika računa vjerojatnosti. Neka U predstavlja prostor mogućih događaja koji su istiniti. U tome slučaju, maksimalna vjerojatnost da je neki događaj istinit mora se nalaziti unutar U [81],

Aksiom 4.1 $P(U)=1$. (1)

Vjerojatnost cijelog promatranog prostora mogućih istinitih događaja U jest 1. Za bilo koje područje X koje se nalazi unutar U vrijedi da njegova površina ne može biti negativna, već u najgorem (ili u najboljem) slučaju 0 (prazan skup). Tako dolazimo i do drugog aksioma,

Aksiom 4.2 Za sve $X \subseteq U$, $P(X) \geq 0$. (2)

Zadnji i posljednji aksiom nam omogućuje računanje vjerojatnosti kombiniranih događaja X i Y (aditivnost),

Aksiom 4.3 Za sve $X, Y \subseteq U$, ako vrijedi $X \cap Y = \emptyset$, tada $P(X \cup Y) = P(X) + P(Y)$. (3)

Svaka funkcija unutar polja U koja zadovoljava navedene aksiome bit će funkcija vjerojatnosti.

Jednostavni teorem predstavlja proširenje aksioma za vjerojatnosti događaja koji se preklapaju (npr. skupovi koji se presijecaju),

Teorem 4.1 Za sve $X, Y \subseteq U$, $P(X \cup Y) = P(X) + P(Y) - P(X \cap Y)$. (4)

Koncept uvjetovane vjerojatnosti je vrlo važan budući da se na njemu uvelike temelje primjene računa vjerojatnosti. Tako je uvjetna vjerojatnost predstavljena kroz sljedeću definiciju,

Definicija 4.1 *Uvjetna vjerojatnost (engl. Conditional probability):*

$$P(X|Y) = P(X \cap Y) / P(Y). \quad (5)$$

To znači, u slučaju da se događaj Y dogodio ili će se dogoditi, vjerojatnost da će se događaj X također dogoditi je $P(X|Y)$. U slučaju da je Y događaj s nula vrijednosti vjerojatnosti, tada uvjetna vjerojatnost postaje nedefinirana.

Sljedeći vrlo važan koncept koji je potrebno predstaviti je koncept *nezavisnosti* (ili *marginalne nezavisnosti*). Dva događaja X i Y su probabilistički nezavisni (notacijom prikazano, $X \perp Y$) u svim onim slučajevima kada postavljanje uvjeta na jednu uvjetnu vjerojatnost drugu ostavlja nepromijenjenu,

Definicija 4.2 *Nezavisnost* $X \perp Y \equiv P(X|Y) = P(X)$. (6)

Uvjetna nezavisnost generalizira koncept u slučajevima kada su X i Y nezavisni u odnosu na neki dodatni događaj Z :

Definicija 4.2 *Uvjetna nezavisnost* $X \perp Y|Z \equiv P(X|Y, Z) = P(X|Z)$. (7)

Ova definicija predstavlja pravu generalizaciju budući da Z može biti prazni skup, u slučaju da je reduciran na marginalnu nezavisnost.

Da bi materija u ovom radu bila cjelovita, svakako treba u spomenuti još dva teorema vezana za uvjetnu vjerojatnost koja su vrlo često u uporabi. Prvi teorem je vezan za, tzv. totalnu vjerojatnost

Teorem 4.2 *Totalna vjerojatnost – pretpostavimo da je skup događaja $\{A_i\}$ dio skupa U , te za svaki udaljeni i i j vrijedi $A_i \cap A_j = 0$, imamo:*

$$P(U) = \sum_i P(A_i). \quad (8)$$

Na isti način je moguće primijeniti teorem na bilo koji događaj B koji je dio cijelog prostora U :

$$P(B) = \sum_i P(B \cap A_i). \quad (9)$$

Drugi teorem je vezan za, tzv. lančano pravilo:

Teorem 4.3 *Lančano pravilo (engl. Chain Rule) koristimo kada imamo više događaja (npr. tri), A , B , C u lancu utjecaja (događaji utječu jedan na drugi). U danom primjeru događaji A i B su neovisno s obzirom na B ,*

$$P(C|A) = P(C|B) P(B|A) + P(C|\neg B) P(\neg B|A), \quad (10)$$

pod pretpostavkom da su uvjetne vjerojatnosti definirane. Ovo pravilo nam omogućuje da podijelimo utjecaj vjerojatnosti C na A preko različitih stanja treće varijable.

Bayesov teorem predstavlja vrlo važan alat za predstavljanje vjerojatnosti. Pomoću njega je moguće vjerojatnosti iskazati kao subjektivni stupanj vjerovanja koji se mijenja u ovisnosti o dokazima. Bayesov teorem je jednostavni teorem računa vjerojatnosti. Razvio ga je engleski matematičar, Thomas Bayes [Slika 4-3]. U sklopu uobičajene interpretacije, teorem sugerira da je vjerojatnost hipoteze h koja je uvjetovana dokazom e , jednaka vjerojatnosti $P(e|h)$ koja je pomnožena izvornom vjerojatnošću (engl. *a priori*) hipoteze h te potom normalizirana na način da se izraz podijeli s vjerojatnošću dokaza e .

Teorem 4.4 *Bayesov teorem*

$$P(h|e) = P(e|h) P(h) / P(e). \quad (11)$$



Slika 4-3. Thomas Bayes (1702 – 1761).

Bayesov teorem predstavlja srce Bayesovih mreža omogućujući pritom korištenje od ranije dostupnog znanja zajedno s novim spoznajama (dokazima, vjerovanjima) s ciljem stvaranja zaključaka, predviđanja i sl.

4.3. Bayesove mreže

Bayesove mreže (engl. *Bayesian Networks*) su grafičke strukture (modeli) koje nam omogućuju predstavljanje i zaključivanje o nedefiniranoj (nesigurnoj, nejasnoj) domeni interesa.

Grafički modeli omogućuju prirodan put ka rješavanju dva velika problema: nesigurnosti i kompleksnosti. Kao dodatak, pružaju metodologiju pomoću koje ljudi i strojevi na intuitivan način mogu modelirati interaktivni skup slučajnih varijabli ili kompleksnih podatkovnih struktura koje omogućuju zaključivanje [82]. Informacije spremljene unutar Bayesove mreže mogu sadržavati analizirane akcije, sekvence događaja, obzervacije, posljedice i očekivanja [83].

Unatoč svojoj relevantnosti, ideja i metodologija Bayesovih mreža još se nije značajnije proširila na druga znanstvena područja kao što su, npr. socijalne i društvene znanosti. Uobičajeni problemi koje Bayesove mreže mogu spriječiti prilikom širenja na druge znanstvena područja uključuju:

- razvoj Bayesovih mreža iziskuje popriličan napor osobe koja pokušava znanje u obliku parametara i strukture mreže implementirati u kompleksni sustav,
- razvoj realnih i koegzistentnih probabilističkih grafova (npr. strukture modela) često zahtjeva suradnju između stručnjaka za pohranu znanja sa stručnjacima ciljane domene, što ponekad može biti teško za ostvariti,

- znanje koje je nastalo na temelju podataka prikupljenih iz različitih izvora – medija (knjige, izvještaji, statistički podaci, itd.) može sadržavati statističke pogreške,
- grafički prikaz Bayesove mreže ovisi o tome kako je specificirana domena. U slučajevima kada ta domena nije dovoljno detaljno ili jasno specificirana moguća je pojava grešaka prilikom zaključivanja,
- prikupljanje znanja od stručnjaka za domenu problema može unijeti u model subjektivna stajališta.

Bez obzira na navedene nedostatke, probabilistički grafički modeli kao što su Bayesove mreže pokazali su se kao moćan alat u radu unutar domena koje su nejasne, odnosno koje nisu dostatno definirane ili im nedostaju informacije [84].

U matematičkoj notaciji, graf G predstavlja skup vrhova V (čvorova) i lukova (linkova) E , na način da je $G = (V, E)$. Čvorovi u Bayesovoj mreži predstavljaju skup varijabli koje se nalaze unutar ciljane domene, $N = \{X_1, X_2, X_3, \dots, X_j, \dots, X_n\}$. U grafičkim modelima lukovi (linkovi) mogu biti usmjereni (engl. *directed*) ili neusmjereni (engl. *undirected*). Skup usmjerenih lukova (ili linkova) spajaju parove čvorova, $X_i \rightarrow X_j$, predstavljajući usmjerene ovisnosti između varijabli. Bayesova interpretacija vjerojatnosti se temelji na principima teorije uvjetne vjerojatnosti. U sklopu Bayesove statistike, uvjetne vjerojatnosti koristimo zajedno sa segmentiranim (ili parcijalnim) znanjem o domeni od interesa. Na primjer, takvo znanje uvjetuje odnose između dva događaja A i B , na način da promjena stanja jednoga utječe na stanje drugoga. Pod pretpostavkom da je događaj B istinit, odnosno da se dogodio, vjerojatnost da je događaj A istinit izražena je pomoću izraza: $P(A|B)$. Ova notacija sugerira sljedeće dvije pretpostavke:

1. dva događaja A i B su međusobno neovisni ako vrijedi $P(A) = P(A|B)$,
2. dva događaja A i B međusobno uvjetno neovisni s obzirom na C ako vrijedi $P(A|C) = P(A|B,C)$.

Napomena: koristeći te dvije pretpostavke, Bayesov teorem moguće je koristiti prilikom zamjene redoslijeda ovisnosti između događaja,

$$3. P(A|B) = P(A,B)/P(B). \quad (12)$$

4. Koristeći Bayesov teorem vrijedi:

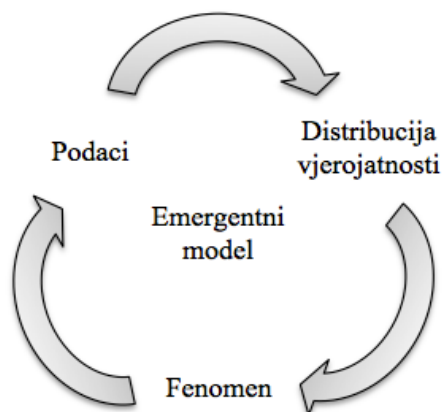
$$P(A|B) = P(B|A) P(A) / P(B),$$

$$P(A|B) = P(B|A) P(A) / P(B) = \frac{P(B|A) * P(A)}{\sum_j P(B|A_j) * P(A_j)}, \quad (13)$$

gdje j označava sva moguća stanja od A .

Koristeći navedene jednačbe, moguće je zaključiti sljedeće o odnosima Bayesovih mreža i uvjetnih vjerojatnosti:

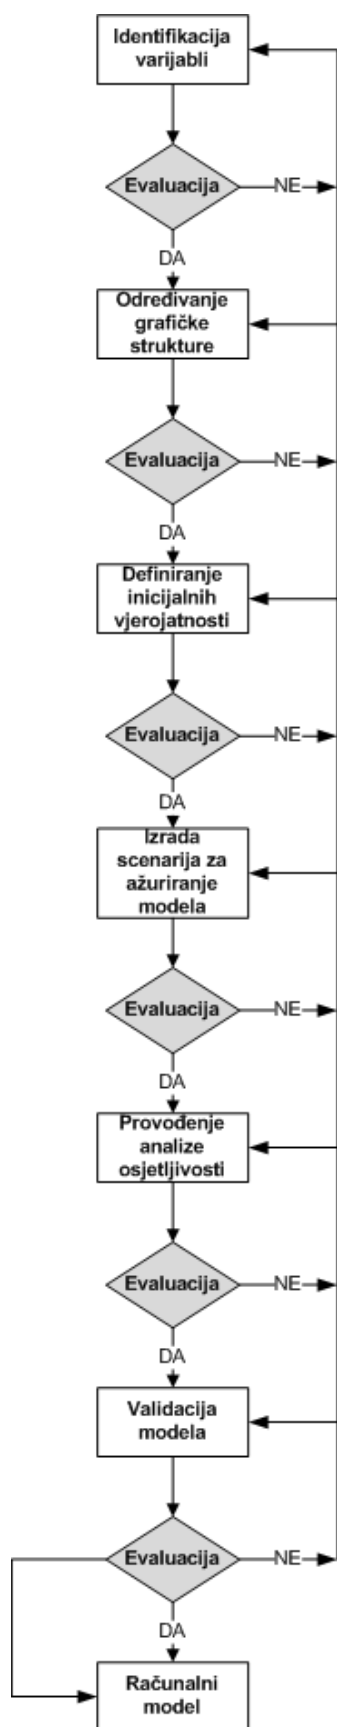
- $P(A|B)$ je posteriorna (uvjetovana) vjerojatnost s obzirom na dokaz B ,
- $P(A)$ je početna (inicijalna) vjerojatnost od A ,
- $P(B|A)$ je vjerojatnost dokaza s obzirom na A ,
- $P(B)$ je inicijalna vjerojatnost dokaza B .



Slika 4-4. Proces modeliranja.

Pod pretpostavkom da su varijable diskretne prirode (iako ne moraju biti), snaga odnosa između varijabli je određena pomoću razdioba uvjetnih vjerojatnosti (engl. *Conditional Probability Distributions*) koje su pridijeljene svakom čvoru. Jedino ograničenje u Bayesovim mrežama je vezano za čvorove i ono govori da u mreži ne smije biti cikličkih kretnji: nije se moguće vratiti u prethodni čvor prateći usmjerene lukove mreže. Zbog toga se Bayesove mreže nazivaju još i acikličke (engl. *DAG – Directed Acyclic Graphs*).

Postoji više koraka koje je potrebno poduzeti prilikom kreiranja Bayesove mreže [97]. Razvoj probabilističkih grafičkih modela u koje spadaju i Bayesove mreže je iterativan. Kako prikazuje proces modeliranja prikazan na slici [Slika 4-4], razvoj probabilističkih modela uključuje organizaciju podataka, ostvarivanje logičkih odnosa među podacima te izrađivanje shema (modela) za predstavljanje znanja.




Slika 4-5. Faze i procedure kod kreiranja Bayesove mreže.

Iako postoje pristupi koji nalažu izbjegavanje unošenja ranijeg (početnog, inicijalnog) znanja u model kako ne bi došlo do pogrešnog zaključivanja (iskustveni podaci mogu odstupati od stvarnih), prilikom izrade modela poželjan je rad sa svim dostupnim podacima čime je olakšana izrada logičkih odnosa te kasnije postupak zaključivanja.

Slika s lijeve strane [Slika 4-5] prikazuje osnovne faze i procedure prilikom izrade Bayesovih mreža. Prvi korak uključuje identificiranje i definiranje domenu problema, uključujući identifikaciju relevantnih varijabli. Jednom kada su varijable definirane kreće se s unošenjem pripadajućih početnih vjerojatnosti. Vrijednosti za vjerojatnosti se procjenjuju na temelju izvora o pripadajućim dokazima (empirijski podaci, vjerovanje stručnjaka iz promatranog područja, literatura, intuicija, itd.). U sklopu drugog koraka utvrđuju se odnosi između varijabli te inicijalna grafička struktura modela. Treći korak se odnosi na primjenu Bayesovog teorema prilikom izračuna vrijednosti uvjetnih vjerojatnosti za svaku varijablu u modelu. U četvrtom koraku razvija se scenarij prema kojem će model biti ažuriran, odnosno scenarij učenja modela. Jednom kada je model ažuriran, u sklopu petog koraka provodi se analiza osjetljivosti kojom se testira rad modela u odnosu na korištene parametre. Validacija modela se provodi tijekom šeste i posljednje, sedme faze izrade. Validacija treba osigurati ispravnost modela, odnosno mora potvrditi da model predstavlja stvarnu sliku opisanog fenomena. Faze modeliranja su završene kada je dobiven stabilan i ispravan računalni model koji predstavlja realno stanje promatranog fenomena unutar domene od interesa.

Bayesov model je obično sastavljen od n varijabli koje su namjerno povezane s onim varijablama na koje imaju utjecaj. To je u literaturi [84] znano kao uvjetna nezavisnost (engl. *conditional independence*) te može biti prikazana na različite načine, npr. kao uzročni lanac (engl. *causal cain*), zajednički

uzrok (engl. *common cause*) ili zajednički utjecaj (engl. *common effect*). Sljedeća slika [Slika 4-6] prikazuje proizvoljni scenarij u kojem A ima zajednički utjecaj na B i C .



Slika 4-6. Primjer uvjetne nezavisnosti.

U slučaju da ne postoje dokazi o A , znanje o događaju B može promijeniti vjerojatnost od C (propagiranjem novog dokaza kroz A). Međutim, u slučaju da je A promatran (stanje od A je poznato), znanje o B ne može promijeniti vjerojatnost od C (putanja između B i C je blokirana dokazom – znanjem o stanju o događaju A) budući da su B i C tzv. d -odvojeni (engl. *d-separated*) s A . D -odvojenost je Bayesovo pravilo koje opisuje odnos između čvorova X i Y respektirajući čvor Z . X i Y su d -odvojeni sa Z u slučaju da nema protoka informacija među njima u trenutku kada je Z promatran [41].

Prilikom razvoja Bayesove mreže znanje stručnjaka se u mrežu obično integrira definirajući uzročne linkove između čvorova. Vrijednosti vjerojatnosti se temelje na subjektivnim procjenama. Pri tome, najteži korak predstavlja prevođenje znanja stručnjaka u numeričke vrijednosti. Nedostaci koji proizlaze iz toga mogu biti prekomjerno samopouzdanje ili iskrivljena slika stručnjaka o činjenicama analiziranog fenomena, neslaganje među stručnjacima za područje, pridjeljivanje previsokih vjerojatnosti događajima koje je lagano za zapamtiti i sl. [85]. Navedeni nedostaci mogu utjecati na kvalitetno određivanje početnih vjerojatnosti.

Jednom kada je inicijalni model postignut, partikularni scenariji se koriste prilikom finih podešavanja mreže.

Navedeni metodologija i koraci bit će demonstrirani kroz primjer koji je vezan za dijagnostiku raka pluća [79].

Primjer: *Pacijent kratko i ubrzano diše te se brzo umara (simptomi ukazuju na bolest zvanu dyspnea). Posjećuje doktora zabrinut u to da nema rak pluća. Doktor na temelju svojeg iskustva zna da osim raka pluća i druge bolesti, kao što su tuberkuloza i bronhitis, imaju slične simptome. Također, doktor zna ostale informacije, uključujući i to je li pacijent pušač*

ili ne (povećava se šansa za rak pluća ili bronhitis) te je li pacijent bio izložen nekoj vrsti zagađenja zraka. Uporaba x-zraka (pozitivan nalaz) može ukazivati da pacijent ima tuberkulozu ili rak pluća.

4.3.1. Čvorovi i vrijednosti

Osoba koja kreira Bayesovu mrežu najprije treba odrediti varijable od interesa. To uključuje odgovore na neka od pitanja kao što su: što predstavljaju čvorovi na mreži te koje vrijednosti ti čvorovi mogu poprimiti? U ovom primjeru bit će pretpostavljeno da čvorovi mogu poprimiti samo diskretne vrijednosti. Navedene vrijednosti moraju biti iscrpne te se trebaju međusobno isključivati (varijabla može u istom trenutku poprimiti samo jedno stanje). Uobičajene diskretne vrijednosti mogu sadržavati:

- Boolean čvorove koji mogu poprimiti vrijednosti *true* (*T*) ili *false* (*F*). U primjeru, čvor koji predstavlja rak pluća će označavati ima li pacijent rak pluća ili ne.
- Čvorove koji poprimaju više mogućih vrijednosti, npr. čvor *Zagađenje* može predstavljati izloženost zagađenom zraku te može poprimiti vrijednosti {niska, srednja, visoka}.
- Cjelovite (integralne) vrijednosti, npr. čvor *Godine* može predstavljati pacijentove godine te može poprimiti vrijednosti od 1 do 120.

Tablica [Tablica 4.1] predstavlja preliminarno odabrane čvorove i vrijednosti za analizirani primjer.

Tablica 4-1. Čvorovi i vrijednosti za analizirani primjer.

Ime čvora	Vrsta	Vrijednosti
<i>Zagađenje</i>	Binarno	{ <i>visoka, niska</i> }
<i>Pušač</i>	Bolean	{ <i>T, F</i> }
<i>Rak</i>	Bolean	{ <i>T, F</i> }
<i>Dyspnoea</i>	Bolean	{ <i>T, F</i> }
<i>X-zrake</i>	Binarno	{ <i>poz, neg</i> }

Kao što je moguće vidjeti, u tablici je pokazan prilično pojednostavljen primjer koji ne sadržava sve mogućnosti za bolesti. Sljedeći “nedostatak“ je to da sustav nema mogućnost razlikovanja, npr. slabih od jakih pušača. Iako je model opisan u tablici sadržava po dvije vrijednosti ne postoji ograničenje u broju vrijednosti koje mogu biti pridijeljene kao stanje za pojedini čvor. Primjer je pojednostavljen kako bi se na što jednostavniji i brži način prikazala metodologija razvoja Bayesovih mreža. Sljedeći korak nakon razvoja mreže za prikazani primjer može biti dodatno proširenje opisa i mogućnosti varijabli u čvorovima mreže.

4.3.2. *Struktura Bayesove mreže*

Struktura ili topologija mreže treba označavati kvalitativni odnos među čvorovima, odnosno varijablama. U osnovi, dva čvora bi trebala biti povezana lukom u slučaju da jedan na neki način utječe na drugi. Smjer luka označava smjer utjecaja jednog čvora na drugi. U ovome trenutku dizajner Bayesove mreže treba razmisliti na koji način utječu čvorovi jedan na drugi te na temelju toga izraditi topologiju mreže.

Slika [Slika 4-7] prikazuje topologiju mreže za dani primjer zajedno s pripadajućim vezanim, odnosno uvjetovanim vjerojatnostima. Kao što je moguće zaključiti iz primjera, postoje varijable koje nemaju direktnog utjecaja na druge. Također, uz dane dokaze te ovisno o smjerovima lukova, neke varijable mogu blokirati širenje utjecaja kroz mrežu (*d-odvajanje*). Da bismo formalno izrazili navedenu interpretaciju potrebno je definirati prikladnu notaciju. U slučaju da Bayesova mreža među ostalima varijablama sadržava i varijablu V , vrijedit će:

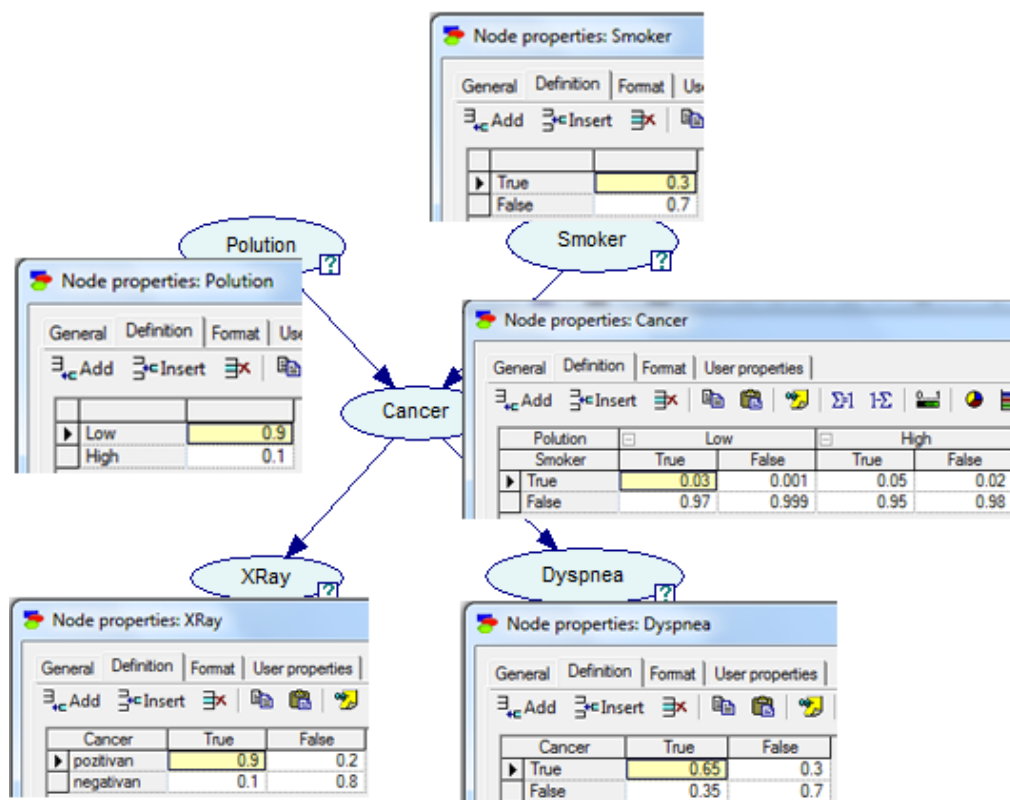
- varijable roditelji od V ($Roditelji(V)$) su sve one varijable N koje imaju direktne lukove (veze) od N do V ,
- varijable potomci od V ($Potomci(V)$) su sve one varijable N koje imaju direktne lukove (veze) od V do N (može se zaključiti da je V predak od N u ovome slučaju),
- varijable koje nisu potomci od V ($Ne_potomci(V)$) su sve one varijable koje nisu V , roditelji od V ili potomci od V ,

Sljedeći navedenu notaciju Bayesove mreže, moguće je formalno interpretirati kao kompaktnu reprezentaciju od sljedećih neovisnih iskaza:

- $I(V, Roditelj(V), Ne_potomci(V))$ za sve varijable u Bayesovoj mreži.

Iz navedenog izraza moguće izvući sljedeći važan zaključak:

- u slučaju da postoji direktan dokaz o stanju neke varijable, naše vjerovanje o toj varijabli više neće biti pod utjecajem drugih varijabli u mreži.



Slika 4-7. Primjer Bayesove mreže - tablice uvjetnih vjerojatnosti.

Koristeći navedenu notaciju primijenjenu na danom primjeru Bayesove mreže, moguće je izraziti sljedeće iskaze o neovisnostima među varijablama (čvorovima):

- $I(XRay, Cancer, \{Pollution, Smoker, Dyspnea\})$,
- $I(Dyspnea, Cancer, \{Pollution, Smoker, XRay\})$,
- $I(Cancer, \{Pollution, Smoker\}, 0)$,
- $I(Pollution, 0, \{Smoker, XRay, Dyspnea\})$,
- $I(Smoker, 0, \{Pollution, XRay, Dyspnea\})$.

Prilikom korištenja formalne reprezentacije Bayesove mreže kao skupa uvjetno neovisnih izraza treba uzeti u obzir da oni sami po sebi ne govore puno o značenju kauzalnosti (o urocima djelovanja, odnosno utjecaja između varijabli).

4.3.3. Parametrizacija neovisnih varijabli

Prvi korak prilikom kreiranja grafičkih struktura koje sadržavaju znanja, odnosno vjerovanja koja opisuju ciljanu domenu problema, podrazumijeva određivanje neovisnih varijabli koje se potom povezuju ovisno o međusobnim utjecajima. U Bayesovim mrežama ti se utjecaji iskazuju uvjetnim vjerojatnostima i to na sljedeći način: za svaku varijablu X zajedno s njenim roditeljima U koji se nalaze unutar promatrane probabilističke grafičke

strukture potrebno je omogućiti vjerojatnost $P(x|u)$. Tablica koja definira utjecaj svih čvorova-roditelja na promatrani čvor-dijete naziva se *tablica uvjetnih vjerojatnosti* (engl. *Conditional Probability Table – CPT*).

Uzevši u obzir navedeno, Bayesovu mrežu je moguće definirati sljedećom formulacijom:

Definicija 4.3 Bayesova mreža u kojoj su sadržane varijable Z ($Z=[Z_1, Z_2, \dots, Z_n]$) predstavlja par (G, Θ) , u kojem je:

- G usmjereni aciklički graf s pripadajućim varijablama Z , koji se naziva struktura mreže,
- Θ skup CPT-ova za svaku varijablu unutar Z , koji se naziva parametrizacija mreže.

Oznaka $\Theta_{X|U}$ označava CPT za varijablu X zajedno s pripadajućim roditeljima U . Za svaku promatranu varijablu (čvor u mreži) vrijedi:

- $\sum_X \Theta_{X|U} = 1$.

Potrebno je uzeti u obzir da veličina CPT od $\Theta_{X|U}$ eksponencijalno raste u ovisnosti o tome koliko varijabla X ima roditelja unutar U . Stoga je strukturu mreže, odnosno broj roditelja po pojedinom čvoru potrebno držati razumno malim. Bayesova mreža razvijena u sklopu ovog rada sadrži najviše pet roditelja i to na jednom čvoru (varijabla *Social Capital*) kako broj uvjetnih vjerojatnosti ne bi bio prevelik.

5. SPOZNAJNI MODEL UPRAVLJANJA GRUPOM INDUSTRIJSKIH ROBOTA

“

Logic will get you from A to Z; imagination will get you everywhere.

”

Albert Einstein

5.1. Agenti, višeagentski sustavi

Prema [86], agent je računalni sustav sposoban za samostalnu akciju u ime korisnika koja je skladu s ispunjenjem zadanih ciljeva bez dodatnih uputa i/ili instrukcija. Agent može biti bilo šta što može opažati okolinu korištenjem senzora, te djelovati u skladu s postavljenim ciljevima. Slika [Slika 5-1] prikazuje model interakcije između agenta i okoline. Prikazani model uključuje:

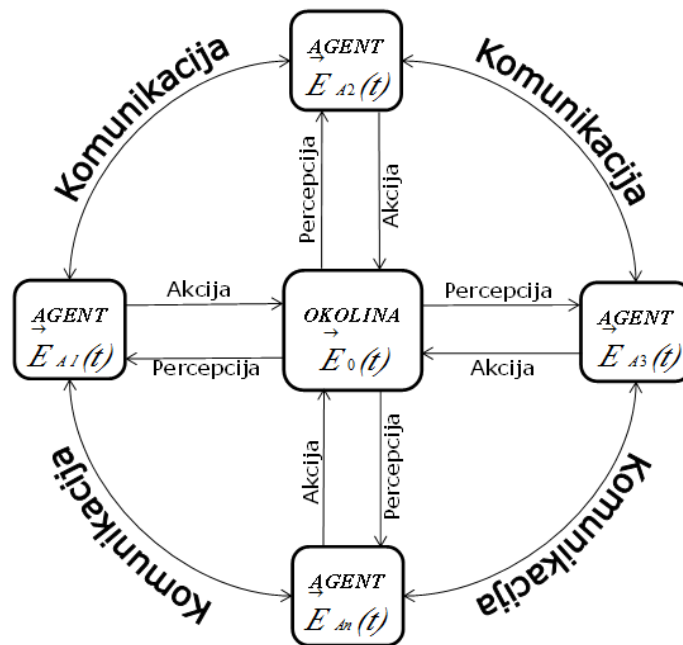
- prikupljanje informacija iz okoline koje se mijenjaju u skladu s vremenskom funkcijom $f_o(t)$ koristeći dostupne senzore (ulazi u sustav) te
- generiranje prikladne akcije agenta u skladu s funkcijom $f_A(t)$.



Slika 5-1. Agent: model interakcije.

Moderni pristupi razvoju umjetne inteligencije usredotočeni su oko pojma *racionalnog agenta* čija je karakteristika da pomoću metoda umjetne inteligencije nastoji u određenoj mjeri optimizirati svoje djelovanje [80]. Te metode uključuju subjekte kao što su zaključivanje, učenje, planiranje, percepcija, prikupljanje znanja, upravljanje temeljeno na nesigurnostima, itd. U ovisnosti o ciljevima djelovanja agenta u njegovoj okolini, navedeni subjekti se implementiraju u funkciju $f_A(t)$ prikazanog modela [Slika 5-1]. Vrlo često je cilj djelovanja agenta vezan za njegovu prilagodbu trenutnom stanju kao što je slučaj kod spoznajnog modela za upravljanje grupom industrijskih robota razmatranog u sklopu ovog

rada. Kroz razvijeni spoznajni model te u ovisnosti o metodologiji i stupnju implementacije, navedeni subjekti agentu omogućuju djelomičnu kontekstualnu spoznaju te relativno samostalno djelovanje. U slučaju da postoji barem dva agenta smještena u okolinu koji međusobno komuniciraju te razmjenjuju relevantne informacije, radi se o višeagentnom sustavu. Prema [87], svaki sustav koji se sastoji od više objekata koje se po određenim kriterijima može dekomponirati na osnovne dijelove može se smatrati višeagentnim sustavom. Slika [Slika 5-2] prikazuje model interakcije kod višeagentskog sustava koji sadrži četiri agenta smještena u okolinu.



Slika 5-2. Višeagentski sustav: model interakcije.

Respektirajući prikazani model interakcije kod višeagentskog sustava, međusobnu interakciju grupe robota s pripadajućom industrijskom okolinom matematičkom formulacijom je moguće definirati kao:

$$\exists G(\vec{E}_{A1}, \dots, \vec{E}_{An}) \forall t_i \rightarrow G_{opt} | \vec{F}, \quad (14)$$

gdje su informacije prikupljene iz okoline pomoću senzora te spoznajni model upravljanja grupom industrijskih robota definirani kao vektori:

$$\vec{E}_A = [\vec{E}_{A1}, \dots, \vec{E}_{An}] = [f_{A1}(S_{11}, \dots, S_{1m}), \dots, f_{An}(S_{n1}, \dots, S_{nm})], \quad (15)$$

i

$$\vec{F} = (CO, BN). \quad (16)$$

Temeljem navedene matematičke formulacije (14), moguće je zaključiti da postoji barem jedna funkcija G koja opisuje kontekst okoline u danom trenutku koristeći informacije

prikupljene pomoću dostupnih senzora prikazanih vektorom (\vec{E}_A) zajedno sa skupom kriterija definiranih u sklopu spoznajnog modela (\vec{F}), tako da generira željeno ponašanje industrijskog robota u odnosu na grupu (G_{opt}). Oznake *CO* i *BN* koje se nalaze unutar vektora skupa kriterija definiranih unutar spoznajnog modela, označavaju ontološku jezgru (*CO* - engl. *Core Ontology*) i Bayesovu mrežu (*BN* – engl. *Bayesian Network*), respektivno.

Pronalaženjem funkcije G_{opt} uz postavljene odgovarajuće kriterije i trenutno stanje okoline uključujući stanja svih relevantnih objekata, rješava se problem donošenja odluka kod agenta unutar grupe, ali i za višeagentski sustav kao cjelinu.

5.2. Spoznajni model

Različiti pristupi i metode ostvarivanja spoznajnog modela bili su višestruko evaluirani prilikom procesa recenzije kod recenzenata od više međunarodnih i stručnih časopisa. Osim u sklopu međunarodnih časopisa, razvijena metodologija je predstavljena i na više međunarodnih, stručnih skupova [89 – 94].

Kontekst prostora i vremena postaje važan čimbenik prilikom razvoja autonomnih sustava. Njegovo shvaćanje može voditi ka mogućnosti sustava da se prilagodi stalnim promjenama koje karakteriziraju realni prostor djelovanja. Svaki objekt, proces ili uvjet je jedinstven po svojoj prirodi. Za agenta koji je sposoban donositi odluke o svojem budućem djelovanju koje nisu u potpunosti i u svakom trenutku jasno definirane koristeći percepciju, znanje i/ili inteligenciju možemo zaključiti da u određenoj mjeri može kontrolirati svoju okolinu. Da bi to mogao, agent mora posjedovati određeno znanje, uključujući procese i ostale relevantne komponente. Iz tih razloga istraživanja novih metodologija su usmjerena ka ostvarivanju adaptivnih, antropomatskih i spoznajnih karakteristika [1].

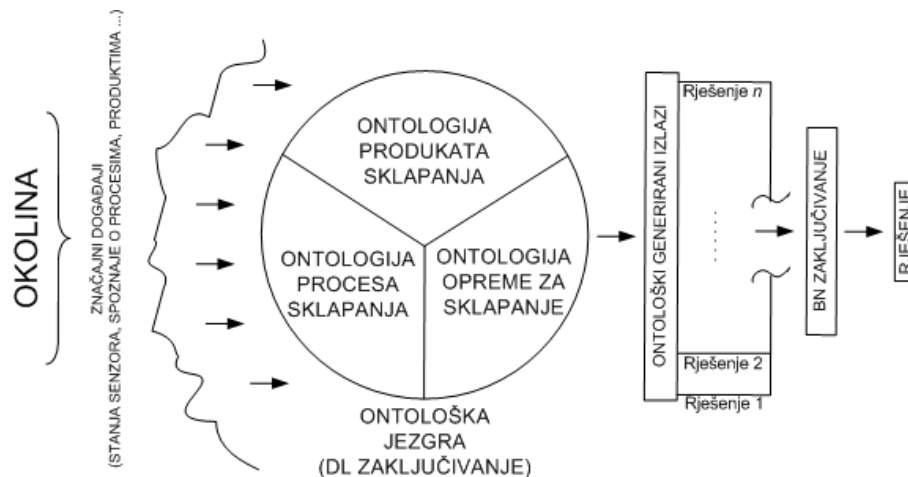
Slika [Slika 5-3] prikazuje spoznajni model za upravljanje grupom industrijskih robota koji je razvijen u sklopu ovog rada. Razvijeni spoznajni model je kao metodologiju moguće iskoristiti prilikom razvoja, integracije i ostvarivanja proizvoljnog sustava djelomično svjesnih konteksta u sklopu različitih aplikacija. Time uporaba modela *NIJE OGRANIČENA* samo na opisanu industrijsku primjenu gdje grupa robota izvodi operacije sklapanja. Iako po svojoj složenosti može predstavljati stvarnu aplikaciju, navedeni primjer je smišljen i realiziran kako bi demonstrirao rad spoznajnog modela.

Spoznajni model uključuje sljedeće komponente:

- sakupljanje informacija pomoću senzora integriranih u okolinu po principima sveprisutnog računarstva,

- semantički opis domene djelovanja koja uključuje opis okoline zajedno sa svim relevantnim procesima i objektima,
- Bayesovu mrežu u kojoj su uključene procjene na temelju iskustva koje moraju omogućiti jedinstveno rješenje za svakog agenta o njegovom djelovanju u ovisnosti o trenutnim kompetencijama grupe (razina procijenjenog socijalnog kapitala).

Sinergija svih komponenti spoznajnog modela osigurava adaptivno ponašanje robota unutar grupe, respektirajući trenutno stanje okoliša i predefinirano znanje o domeni interesa.



Slika 5-3. Spoznajni model za upravljanje grupom industrijskih robota.

Prvi dio modela uključuje sakupljanje implicitnih informacija iz okoline. Koristeći principe sveprisutnog računarstva, senzori iz okoline osiguravaju konstantan dotok svježih informacija koje se potom dovode na ulaz u ontološku jezgru modela. Na ovom dijelu započinje transformacija sakupljenih informacija koje predstavljaju trenutni kontekst u eksplicitne informacije razumljive računalima. Na temelju trenutnog stanja o dostupnim resursima, trenutno aktivnim procesima i definiranoj ontologiji, ontološka jezgra donosi preporuke o mogućim akcijama. U tome koraku dolazi do izražaja, tzv. pretpostavka otvorenog svijeta na kojoj se ontologije temelje. Po njoj su sva rješenja jednako vrijedna što može rezultirati neodlučnošću sustava. Stoga se preporučene akcije (ontološki generirani izlazi) dovode na ulaz Bayesove mreže koja na kraju osigurava jednoznačno rješenje u vidu eksplicitne informacije razumljive robotu (agentu). Rješenje predstavlja programsku rutinu (*BP* – uzorak ponašanja) koja se potom pokreće na robotu.

Koristeći zaključivanje uz pomoć Bayesove mreže koja je dio modela i u koju su ugrađene procjene (vjerojatnosti) o dobrotama mogućih akcija u ovisnosti o kontekstu, robot je sposoban pokretati unaprijed definirane i ontološki opisane programske rutine. To mu daje sposobnost da reagira naizgled nepredvidljivo procjenjujući svoje buduće akcije koristeći

kontekst, odnosno vjerovanje u socijalni potencijal grupe čiji je član. Također, mreža sadrži varijablu *Samoprocjena* (engl. *Self Assessment*) pomoću koje se dokazuju kompetencije robota. Ta varijabla utječe na procjenu hoće li se robot pouzdati u svoje ili u kompetencije grupe. Bayesova mreža koristi koncept realiziran kod stvarnih ljudskih zajednica kod kojih postoji određena razina socijalnog kapitala koja označava mjeru, odnosno potencijal grupe da zajedno radi (surađuje) na realizaciji nekog zadatka.

Koristeći razvijeni model koji uključuje uporabu senzora po uzoru na živa bića, robot u grupi postaje sposoban pretvoriti svoj svakodnevni okoliš u sveprisutni (engl. *ubiquitous*).

5.3. Okolina

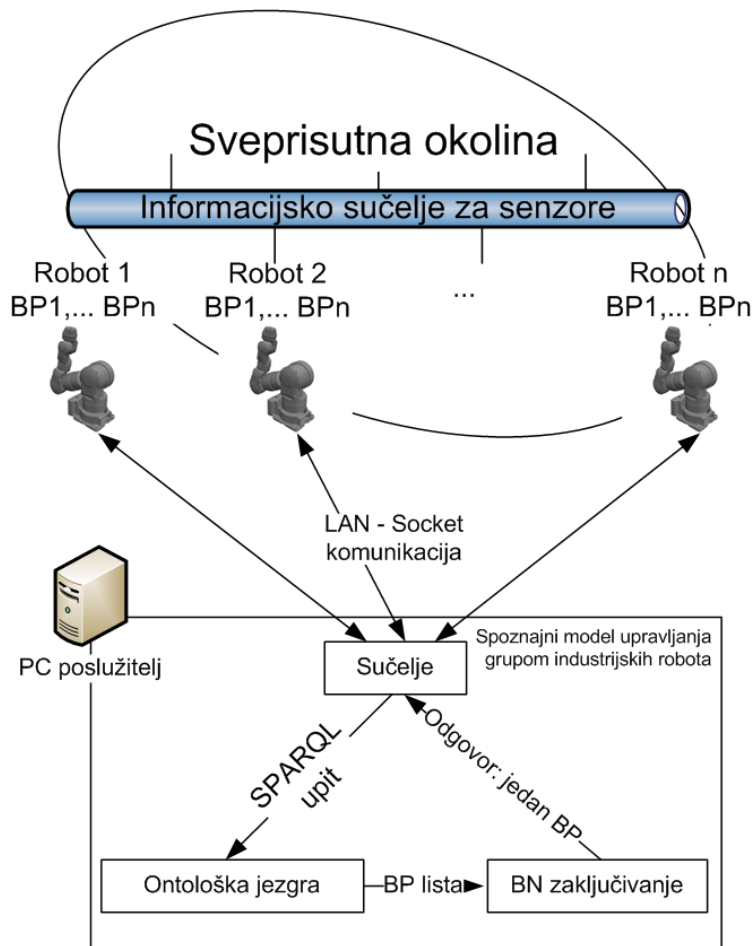
Kako, kada i koje podatke sakupiti iz okoline vrlo su važna pitanja koja mogu voditi ka kontekstualnoj spoznaji okoline. Odgovori u najvećoj mjeri ovise o vrsti i ciljevima promatrane aplikacije te zahtijevaju njenu temeljitu analizu. Ta analiza treba otkriti prostorne i vremenske ovisnosti, te karakteristike procesa, opreme i objekata unutar ciljane okoline interesa. U robotskoj/automatskoj montaži informacije o poziciji i orijentaciji radnog dijela zajedno s ostalim relevantnim objektima i procesima predstavljaju esencijalne podatke za razvoj i primjenu kontrolnih mehanizama. Promjene tih informacija proizlaze iz promjene stanja okoline. One se najčešće mogu predvidjeti, odnosno može se reći da su očekivane. U skladu s nedeterminističkom prirodom okoline, te respektirajući ideju sveprisutnog računarstva, te promijene je relativno lako za kontrolirati. Pravovremeni unos relevantnih informacija može omogućiti fleksibilno, odnosno adaptivno ponašanje sustava. Taj pristup može voditi do ostvarivanja, tzv. pametnog okoliša (engl. *smart environment*). Prema definiciji [95],

pametni okoliš predstavlja fizički svijet koji je bogato i neprimjetno isprepleten sa senzorima, aktuatorima, monitorima i ostalim računalnim elementima koji su mrežno povezani i integrirani.

5.4. Predložena arhitektura sustava

U sklopu zadnje faze razvoja spoznajnog modela, verifikacija i validacija su provedene na lokalnom *PC* računalu koje sadrži svu potrebnu softversku i hardversku podršku. Prilikom razvoja i ispitivanja spoznajnog modela čitava komunikacija između komponenti (unošenje vrijednosti signala sa senzora, unošenje informacija o odabranim uzorcima ponašanja i sl.) odvijala se ručnim unosom. Računalo sadrži *TopBraid Composer* koji pruža cjelovito rješenje

za razvijanje i ispitivanje ontološke jezgre. Ispitivanje je provedeno pomoću *SPARQL Query* editora koji je dio *TopBraid-a* te koji je poslužio kao korisničko sučelje za postavljanje upita ontološkoj jezgri.



Slika 5-4. Arhitektura sustava.

Na isti način će roboti putem *SPARQL* upita kontaktirati spoznajni model koji će biti smješten na posebnom poslužiteljskom računalu u sklopu realnog industrijskog postava u Laboratoriju za projektiranje izradbenih i montažnih sustava na Fakultetu strojarstva i brodogradnje, [Slika 5-4].

Nakon što je *TopBraid* softver vrati rješenje kao odgovor na *SPARQL* upit u vidu jednog ili nekoliko uzoraka ponašanja, Bayesova mreža će na temelju procijene vezane za socijalni kapital grupe te samoprocjene, robotu vratiti jedinstveno rješenje u vidu jednog uzorka ponašanja baš kao što je to radila za vrijeme provođenja verifikacija. Unutar stvarnog postava, roboti će s poslužiteljskim računalom na kojem je spoznajni model pohranjen komunicirati pomoću *Socket Messaging* poruka koje se temelje na *TCP/IP* mrežnoj komunikacijskoj tehnologiji. Rad dostavne trake bit će upravljan posebnim kontrolerom koji je povezan s robotima pomoću *DeviceNet* mrežne komunikacijske tehnologije. Preko toga kontrolera

roboti će moći po potrebu uključivati i isključivati signale koji će propuštati ili zaustavljati nosače proizvoda na dostavnoj traci unutar promatranog radnog mjesta (*BP1*, *BP2*).

5.5. Implementacija spoznajnog modela u stvarnu okolinu

Jedan od sustava ostvarenih kroz interakciju s okolišem je prikazan na sljedećoj slici [Slika 5-5].




Slika 5-5. Okolina karakteristična za izvođenje poslova industrijskog sklapanja


Sustav sadrži tri šesto-osna robota smještena uz montažnu liniju zajedno s pripadajućim sensorima i ostalom opremom. Njegove sastavnice su semantički opisane unutar razvijenog spoznajnog modela. Sustav se nalazi u sklopu Laboratorija za projektiranje izradbenih i montažnih sustava, Fakulteta strojarstva i brodogradnje, Sveučilišta u Zagrebu, i koristi se za različite namjene. Jedna od njih je razvoj metodologija i opreme za sklapanje različitih proizvoda različitih proizvođača. Sustav koristi više vrsta senzora smještenih u okoliš u svrhu pravovremenog i primjerenog reagiranja na promjene, zaustavna mjesta koja omogućuju precizno sklapanje, konvejjere za unos dijelova u sustav te palete za pohranu proizvoda. Kao takav, poslužit će za buduću implementaciju modela u stvarnoj okolini.

Budući da se pred industrijsku proizvodnju vrlo često postavljaju zahtjevi kao što su visok stupanj automatizacije te velike proizvodne serije, suvremene robotske linije za sklapanje si ne mogu dopustiti pogreške proizašle iz nedeterminističke prirode okoline. Stoga se takvi industrijski okoliši obično unaprijed determiniraju što je moguće više.

Kao što je ranije napomenuto, prilikom razvoja te za potrebe ispitivanja spoznajnog modela, kreiran je prototip okoliša sličnog postava koji uključuje robote, palete, senzore i procese potrebne za sklapanje imaginarnog proizvoda. Kao što je moguće vidjeti [Slika 5-6, Slika 5-7], imaginarni proizvod je sastavljen od tri ugradbena elementa (pravokutna osovinica te gornja i donja pločica).



Slika 5-6. *Imaginarni proizvod (izometrija).*




Slika 5-7. *Imaginarni proizvod (detalji).*

Pravokutna osovinica omogućuje spoj gornje i donje pločice. Konačan spoj osiguran je pravokutnim oblikom (onemogućeno je zakretanje oko osi simetrije) te uskočnom značajkom (onemogućeno je rastavljanje dijelova nakon sklapanja). Spoj donje pločice i pravokutne osovinice čini sklop. Spoj sva tri ugradbena elementa čini gotov proizvod. Pomoću dvije posebno oblikovane hvataljke roboti vrše operacije rukovanja i umetanja. Pretpostavljeno je

da su nosač dijelova i paleta posebno oblikovani za prihvat ugradbenog elementa ili sklopa, odnosno gotovih proizvoda.

Da bi ontologija bila uspješno definirana, okoliš je podijeljen na karakteristične sastavnice [93]. Glavna podjela uključuje liniju za sklapanje (*AL* – engl. *Assembly Line*) i radna mjesta (*WP* – engl. *Working Places*). Linija za sklapanje sadrži nosače dijelova (*PC* – engl. *Part Carriers*), te može sadržavati i dodatne senzore u ovisnosti o potrebama aplikacije.

Jedno radno mjesto (*WP* – engl. *Working Place*), prikazano na slici [Slika 5-8] sadrži konvejer (*C* – engl. *Conveyor*), paletu (*P* – engl. *Pallet*), vizijski senzor smješten iznad zaustavnog mjesta (*VS1* – engl. *Vision Sensor 1*), robota (*R* – engl. *Robot*), vizijski senzor smješten na robotu (*VS2* – engl. *Vision Sensor 2*), izmjenjivač alata (*TC* – engl. *Tool Changer*), te zaustavno mjesto (*SP* – engl. *Stopping Place*) i kapacitivni senzor (*CS* – engl. *Capacitive Sensor*) smješteni na liniji. Radna mjesta su međusobno povezana linijom za sklapanje (*AL*) koja omogućuje transport nosača dijelova (*PC*). Nosači dijelova se koriste prilikom transporta ugradbenih elemenata (dijelova), sklopova ili gotovih proizvoda. Komponente radnog mjesta čine senzori (na zaustavnom mjestu, kapacitivni senzor, izmjenjivač alata, itd.), robot - agent, konvejer i paleta.



Slika 5-8. Izgled radnog mjesta.

Zaustavno mjesto (*SP*) se koristi da po potrebi propusti ili zaustavi nosač dijelova, respektirajući logiku definiranu unutar ontološke jezgre, te stanja senzora ostalih radnih mjesta. Njegova glavna funkcija je da osigura nesmetan rad robota prilikom operacija sklapanja i/ili manipulacije s objektima od interesa. Budući da razmatrane operacije zahtijevaju visoki stupanj preciznosti (umetanje dijelova u rupe s malom zračnošću i sl.), zaustavno mjesto mora neutralizirati utjecaj smetnji iz okoline (vibracija i sl.).

Stanje izlaznog signala kapacitivnog senzora (*CS*) smještenog na zaustavnom mjestu (*SP*) se koristi kao parametar prilikom identifikacije uzoraka ponašanja. Značenje pojedinog uzoraka ponašanja detaljno je objašnjeno u sljedećem poglavlju.

Novi dijelovi ulaze u sustav pomoću konvejera (*C*). U trenutku kada novi dio prekine optičku zraku, optička barijera (*OB*) kao senzor smješten na kraju konvejera, mijenja stanje svojeg izlaznog signala te zaustavlja konvejer.

Kapacitivni senzor (*CS*) smješten na liniji za sklapanje odmah iza zaustavnog mjesta, daje informaciji o popunjenosti promatranog radnog mjesta. U slučaju da je senzor aktivan može se zaključiti da je radno mjesto popunjeno paletama. Navedena informacija se koristi prilikom identificiranja prikladnih uzoraka ponašanja.


U razmatranom primjeru primijene, izmjenjivač alata (*TC*) može pohraniti dva alata koje robot koristi prilikom operacija rukovanja i umetanja. Svaki alat ima svoje mjesto za pohranu zajedno s pripadajućim senzorom – indikatorom zauzetosti mjesta (*TC1* i *TC2*). Vrijednosti senzora koristi ontološka baza prilikom identificiranja prikladnih uzoraka ponašanja.

Sustav koristi dva vizijska senzora (*VS1* i *VS2*). Prvi senzor (*VS1*) je smješten iznad zaustavnog mjesta i daje informacije u zauzeću nosača dijelova. Taj senzor daje sustavu vrijednosti je li nosač dijelova prazan, odnosno da li se u njemu nalaze ugradbeni element (dio), sklop ili gotov proizvod. Drugi vizijski senzor (*VS2*) se nalazi na robotskoj ruci i korišten je kod lokalizacije objekata na konvejeru, odnosno prilikom umetanja sklopljenih proizvoda u paletu. Informacije prikupljene od vizijskih senzora korištene su prilikom identificiranja prikladnih uzoraka ponašanja.


Paleta se koristi prilikom smještaja gotovih, odnosno sklopljenih proizvoda. Informacije o popunjenosti palate se ne koriste prilikom identificiranja prikladnih uzoraka ponašanja. U slučaju da robot primjenom vizijskog senzora (*VS2*) ne može pronaći slobodno mjesto na paleti za smještaj proizvoda, robot će signalizirati da je paleta popunjena.

Rad pokretne trake, koji uključuje propuštanje ili zaustavljanje nosača dijelova na zaustavnim mjestima, promjenu stanja izlaznih te praćenje ulaznih senzorskih signala u skladu s događajima u okolišu i sl., upravljan je na globalnoj razini pomoću posebnog kontrolera. Sličan princip centraliziranog upravljanja gdje jedan glavni (master) kontroler upravlja radom sustava na razini ispod, uobičajeni je postav recentnih industrijskih sustava za sklapanje. Sve komponente su međusobno povezane pomoću *DeviceNet* mrežne tehnologije [96]. Kontroler pruža komunikacijsko sučelje preko kojeg roboti mogu pratiti stanja signala.

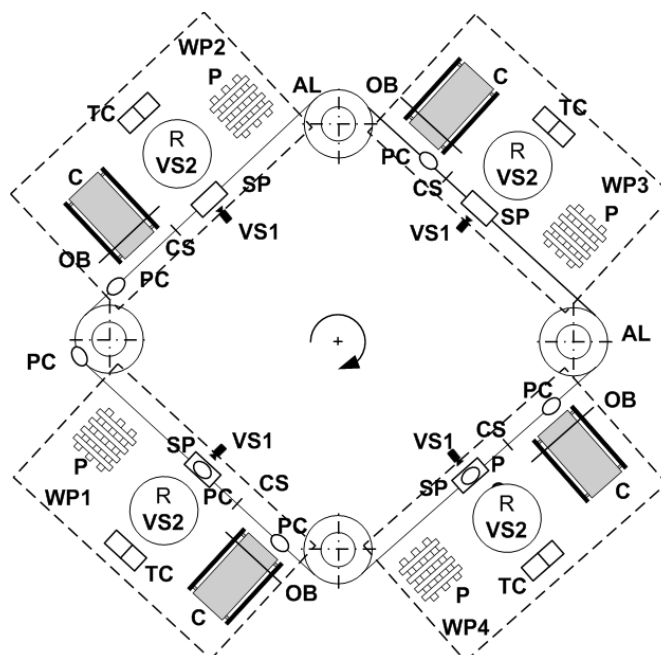
Slike [Slika 5-9, Slika 5-10, Slika 5-11] prikazuju izgled okoline za konfiguraciju s dva, tri i četiri radna mjesta.



Slika 5-9. Izgled okoline za konfiguraciju s dva radna mjesta.



Slika 5-10. Izgled okoline za konfiguraciju s tri radna mjesta.



Slika 5-11. Izgled okoline za konfiguraciju s četiri radna mjesta.

Izgled okoline je odabran na način da slijedi principe skalabilnosti što znači da je dodavanjem ili oduzimanjem radnih mjesta (*WP*), uključujući pritom sve pripadajuće objekte, moguće povećati ili smanjiti kapacitet sustava u cjelini. Time se ne zadire u ontološku definiciju radne okoline budući da je klasa radnog mjesta (*WP*) definirana zajedno s pripadajućim relacijama među objektima pripadnicima klase. Dodavši klasu *WP*, sustav istovremeno dobija sve podklase navedene klase kao što su: *R* (robot), *SP* (zaustavno mjesto), *CS* (kapacitivni senzor), *WSI* (vizijski senzor 1), itd. Opis ontologije zajedno sa svim klasama i podklasama te njihovim pripadajućim objektima i svojstvima dan je u nastavku rada.

Sljedeća prednost navedenog pristupa prilikom definiranja okoline leži u mogućnosti, odnosno sposobnosti sustava prilagodbe trenutnoj ili trajnoj nemogućnosti pojedinog radnog mjesta da obavlja svoju primarnu zadaću, npr. uslijed kvara ili nedostatka neke od komponenti. Tada su ostala radna mjesta sposobna preuzeti, odnosno nastaviti sklapanje serije proizvoda budući da su sastavljena od funkcionalno istih, odnosno sličnih sastavnih dijelova (engl. *self-healing, self-recovery, self-configuring, self-optimizing or self-protecting system capability* [78]).

Posljednju i svakako ne najmanje važnu prednost koju ostvaruje spoznajni model moguće je pojmiti u načinu uporabe senzora prilikom prikupljanja relevantnih informacija. Senzori su smješteni tako da omogućuju potrebne, pravovremene i nedvosmislene informacije o prostornom i vremenskom stanju okoline. Osim što je time domena od interesa postala konstantno analizirani prostor što je u skladu s načelima, tzv. sveprisutnog računarstva, stvoreni su preduvjeti za stvaranje, tzv. aplikacija svjesnih konteksta koje svoje odluke ne temelje samo na eksplicitnim informacijama već i na kontekstu (engl. *context-aware applications*).

5.6. Ontološka jezgra modela

Ontologije označavaju formalnu reprezentaciju entiteta (klasa) zajedno s njihovim pripadajućim atributima (objektima) te njihovim međusobnim odnosima (relacijama). Budući da dopuštaju kreiranje i pohranu znanja o proizvoljnoj domeni te mogu pojednostavniti rad krajnjim korisnicima, pokazale su se kao posebno prikladne. Da bi se izbjegli nedostaci kao što su unošenje osobnih iskustava i vjerovanja, što može uzrokovati preklapanja, razlike i proturječnosti koje se pojavljuju kod ontologija koje su razvili različiti autori koji opisuju istu domenu, dobra je praksa uključiti više osoba prilikom procesa razvoja. Navedeni pristup najčešće rezultira s finalnom ontologijom koja objektivnije prikazuje domenu interesa.

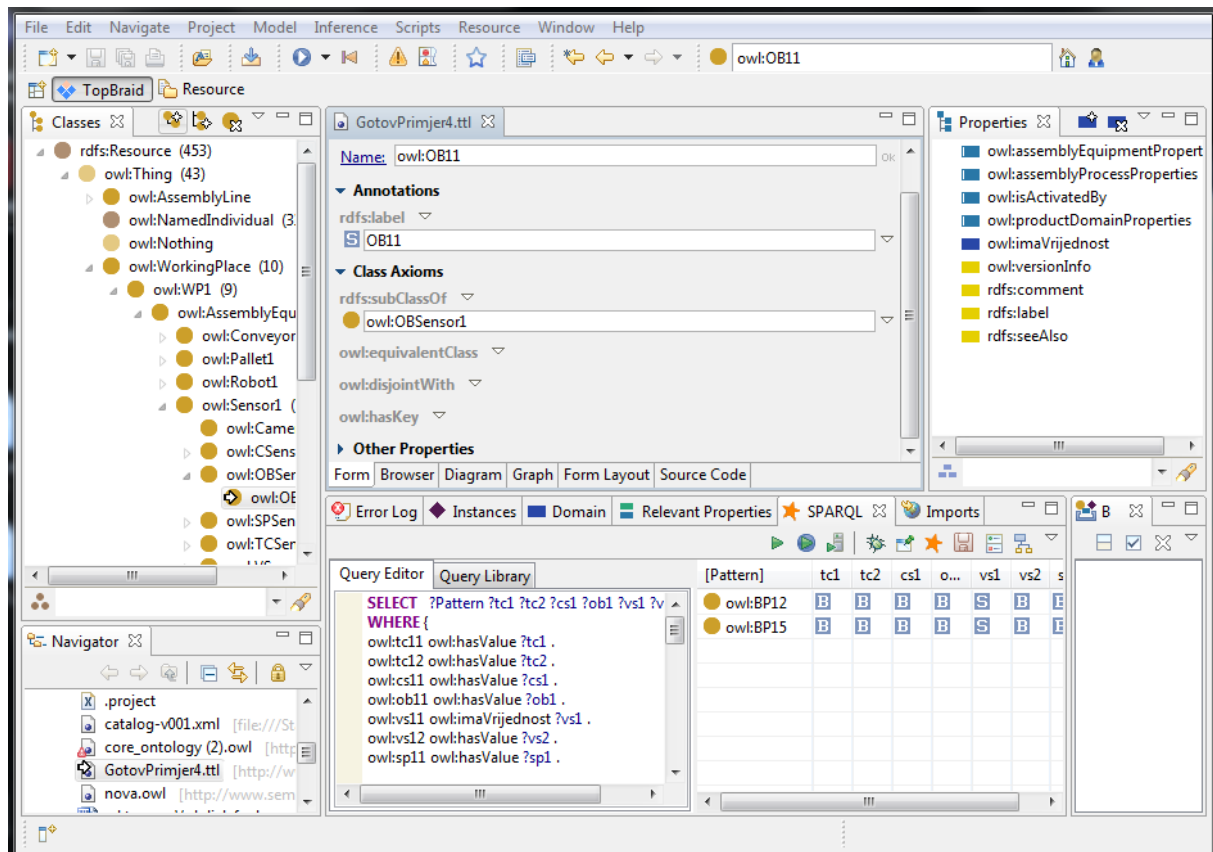
Prema meta-procesu razvoja ontologija opisanom u prethodnom poglavlju [Slika 3-6], prilikom razvoja ontološke jezgre najprije je provedena studija izvodljivosti, koja je uključivala identificiranje potencijalnih problema i specifičnosti aplikacije te izbor alata za izradu ontologije. Budući da je jedan od zahtjeva rad spoznajnog modela u realnom vremenu, donesena je odluka da struktura inicijalne ontologije ne bude prekompleksna, tj. da ne sadrži prekompleksne logičke izraze. Da bi se stekao preduvjet za uspješnu implementaciju kompleksnijih logičkih izraza unutar ontologije smještene u realnu okolinu, najprije treba postojeći spoznajni model dostatno testirati te pronaći odgovarajuću mjeru koja bi mu omogućila odziv u realnom vremenu. Stoga je model razvijen na način da uzorci ponašanja (*BP*), koji su pohranjeni i koji se pokreću na strani robota, umjesto ontologije sadržavaju kompleksnije programske rutine koje mogu izvršavati čitav niz operacija. Alternativa tome bila bi da se programske rutine definiraju unutar same ontologije što bi rezultiralo značajnim povećanjem kompleksnosti iste, što bi opet dovelo u pitanje mogućnost vraćanja ispravnog odziva od strane spoznajnog modela u realnom vremenu.

Drugi problem proizlazi iz činjenice da je *SPARQL* upitni jezik (engl. *SPARQL Query Language*) razvijen primarno za rad s *RDF-om* i *RDFS-om* čije strukture ne podržavaju deskriptivnu logiku. *SPARQL* jezik je korišten da bi se ontološkoj jezgri prenijeli parametri o trenutnom stanju senzora smještenih u okolini. U slučajevima kada su prilikom izrade ontologije pomoću *OWL-DL* jezika korištene relativno kompleksne logičke rečenice, postoji vjerojatnost da zbog nedovoljne razvijenih hardverskih i softverskih komponenti koje su potrebne za smještaj ontologije, baza znanja ne vrati očekivana rješenja nakon postavljanja *SPARQL* upita.

Navedena analiza nije dio disertacije te predstavlja preinaku koju će sadržavati neka od budućih verzija spoznajnog modela. Očekuje se da će to rezultirati povećanjem robusnosti te generalizacijom modela budući da su razvijeni uzorci ponašanja upotrebljivi za specifičan slučaj semantički opisane okoline.

Kao idealan izbor alata za izradu ontologija pokazao se *TopBraid Composer*. *TopBraid Suit* je paket softverskih alata za izradu aplikacija za semantički web. *TopBraid Composer* [Slika 5-12] je alat korišten za povezivanje podataka, postavljanje upita (engl. *query*), modeliranje pravila i ontologije. Prema definiciji *TopBraid Composer* pripada, tzv. integriranim razvojnim okolinama (engl. *IDE – Integrated Development Environment*) za izradu semantičkih aplikacija. Za izradu ontološke jezgre korišten je *Maestro Edition (TBC – ME)* verzija koja je optimizirana za izradu web aplikacija i usluga baziranim na *TopBraid Live* platformi. *TopBraid Composer – Maestro Edition* je dostupan za korištenje i u probnoj

(engl. *trail*) verziji u trajanju od 30 dana. Uz vlastiti interni web poslužitelj za ispitivanje aplikacije, *TBC – ME* sadrži i alate za razvoj aplikacija: *SPARQL Rules*, *SPARQL Web Pages* i *SPARQLMotion data processing*. Zasnovan je na *Eclipse* platformi, omogućava potpunu podršku formatima *owl* i *rdfs*, sadrži rutine za zaključivanje (engl. *inference engine*) te može izvršavati *SPARQL* upite preko posebnog sučelja.



Slika 5-12. TopBraid Composer editor.

Kao što je ranije naglašeno, glavni zadatak ontološke jezgre je pohrana ekspertnog znanja o domeni interesa. Ontološka jezgra predstavlja tek prvu stepenicu u pretvorbi implicitnih informacija u eksplicitne koje su razumljive računalu. Na temelju pohranjenog znanja, jezgra nudi jedno ili skup mogućih rješenja u ovisnosti o stanjima senzora unutar sveprisutne okoline. Koristeći rečenice deskriptivne logike, koje povezuju različite klase i individue unutar klasa, ontološka jezgra preslikava ulazna stanja senzora robota koji je pomoću *SPARQL* jezika poslao upit.

Na temelju odziva na *SPARQL* upit za pojedino radno mjesto, ontološka jezgra predlaže jedno ili više rješenja u vidu, tzv. uzoraka ponašanja (*BPs* – engl. *Behavioral Patterns*). Uzorak ponašanja je programski slijed instrukcija definiran algoritmom, te sadrži definiciju onoga što robot treba napraviti kao odziv na trenutno stanje okoline, uključujući:


- provjeru odsutnosti/prisutnosti objekata od interesa,
- upravljanje stanjem signala zaustavnog mjesta u svrhu propuštanja/zadržavanja nosača proizvoda na liniji za sklapanje, i
- predefinirane i svrsishodne kretnje robota prilikom zamjene alata ili manipulacije objektima od interesa.

Dakle, uzorci ponašanja su programi pohranjeni u robotu koji označavaju skup radnji koje robot izvršava u ovisnosti o trenutnom stanju okoline. Trenutak kada nosač dijelova stigne na zaustavno mjesto označava trenutak u kojem se provjere stanja senzora, te generira i šalje *SPARQL* upit. Kao reakciju na stanje senzora, ontološka jezgra predlaže jedan ili više uzoraka ponašanja. Tablica [Tablica 5-1] prikazuje logičku ovisnost stanja senzora (ulaza u sustav) i uzoraka ponašanja (izlaza iz sustava).

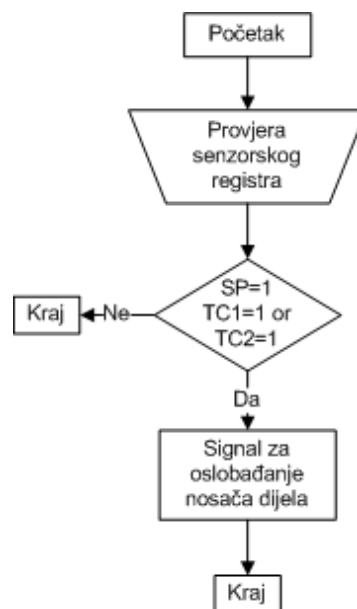
Tablica 5-1. Prikaz ovisnosti izlaznih o ulaznim vrijednostima.

	<i>TC2</i>	<i>TC1</i>	<i>CS</i>	<i>OB</i>	<i>VS2</i>	<i>VS1</i>	<i>SP</i>	<i>BP</i>
1	0	1	0	0		0	1	<i>BP1, BP2</i>
2	1	0	0	0		0	1	<i>BP1, BP2</i>
3	0	1	0	0		<i>Part, Assembly</i>	1	<i>BP1, BP2</i>
4	1	0	0	0		<i>Part, Assembly</i>	1	<i>BP1, BP2</i>
5	0	1	0	0		<i>Product</i>	1	<i>BP3</i>
6	1	0	0	0		<i>Product</i>	1	<i>BP3</i>
7	0	1	0	1		0	1	<i>BP4</i>
8	1	0	0	1		0	1	<i>BP4</i>
9	0	1	0	1		<i>Part, Assembly</i>	1	<i>BP5</i>
10	1	0	0	1		<i>Part, Assembly</i>	1	<i>BP5</i>
11	0	1	0	1		<i>Product</i>	1	<i>BP3</i>
12	1	0	0	1		<i>Product</i>	1	<i>BP3</i>
13	0	1	1	0		0	1	<i>BP1, BP2, BP3</i>
14	1	0	1	0		0	1	<i>BP1, BP2, BP3</i>
15	0	1	1	1		0	1	<i>BP2, BP4</i>
16	1	0	1	1		0	1	<i>BP2, BP4</i>
17	0	1	1	1		<i>Part, Assembly</i>	1	<i>BP2, BP5</i>
18	1	0	1	1		<i>Part, Assembly</i>	1	<i>BP2, BP5</i>
19	0	1	1	1		<i>Product</i>	1	<i>BP2, BP3</i>
20	1	0	1	1		<i>Product</i>	1	<i>BP2, BP3</i>

Kao što je iz tablice moguće vidjeti, za dano radno mjesto smješteno u definiranu okolinu razvijeno je pet uzoraka ponašanja. Tako na primjer, za stanje gdje su aktivirani senzori *TC1*, *CS*, *OB*, *VS2* i *SP*, ontološka jezgra modela agentu će sugerirati odabir jednog od dva uzorka ponašanja, *BP1* ili *BP2*. Navedena logika je implementirana u ontološku jezgru modela. Jednoznačan odabir uzorka ponašanja ovisi o vjerovanju stručnjaka u razinu socijalnog kapitala kao potencijala grupe robota da zajednički radi na izvršavanju nekog zadatka. Navedena rješenja su ostvarena uz pomoć Bayesove mreže, kako je objašnjeno u nastavku disertacije. Kao što je moguće vidjeti, tablica sadrži dvadeset tvrdnji te definira logiku preslikavanja različitih kombinacija stanja senzora u jedno ili više mogućih rješenja u vidu uzoraka ponašanja. Logika koja je definirana i pohranjena unutar tablice se koristi za kontrolu ponašanja robota na njegovom radnom mjestu. Skoro sve vrijednosti koje označavaju promijene unutar okoline detektirane sa sensorima su tipa *Boolean* (0 ili 1, *False* ili *True*). Jedino vizijski senzori (*VS1*, *VS2*) koriste znakove prilikom prepoznavanja objekata od interesa. Važno je primijetiti da je za neke vrijednosti senzora definirano više odziva, odnosno rješenja. To je moguće budući da ontologija po svojoj prirodi slijedi principe otvorenog svijeta (*OWA*) što znači da joj je dozvoljeno da za jedan upit vrati jedan ili više jednako vrijednih odgovora.



Slika 5-13. Algoritam prvog uzorka ponašanja (BP1).



Slika 5-14. Algoritam drugog uzorka ponašanja (BP2).

Kada ne bi postojala Bayesova mreža kao dio spoznajnog modela koja rješava probleme neodlučnosti, u ovakvom postavu sustav ne bi znao koje rješenje odabrati.

Slika [Slika 5-13] prikazuje algoritam s definicijom prvog uzorka ponašanja (*BPI*). Kao što je moguće vidjeti, ovaj uzorak ponašanja označava čekanje agenta za konstantni vremenski period t . Njime agent zadržava trenutno stanje radnog mjesta na način da zadržava nosač dijelova na zaustavnom mjestu.

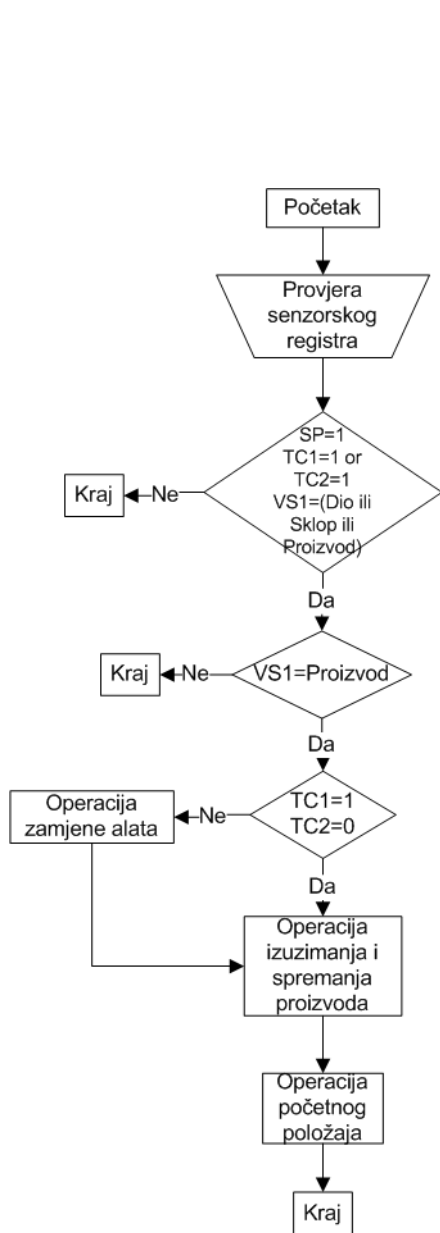
Nakon što sačeka vremenski period definiran varijablom t , agent ponovno provjerava stanje signala te šalje *SPARQL* upit ontološkoj jezgri. U slučaju da je došlo do neke promjene (npr. novi dio koji ulazi u sustav pomoću konvejera prekida zraku na optičkoj barijeri), stanje ulaznih signala se mijenja i ontološka jezgra na temelju trenutnog stanja okoline može predložiti Bayesovoj mreži novi skup uzoraka ponašanja. Koristeći *BPI* moguće je zadržati nosač dijela na trenutnom radnom mjestu sve dok spoznajni model (dio vezan za zaključivanje temeljeno na probabilitici) ne odluči drugačije.

Sljedeća slika [Slika 5-14] prikazuje algoritam drugog uzorka ponašanja (*BP2*). *BP2* je vrlo sličan prvome s razlikom da agent umjesto da zadrži nosač dijela na zaustavnom mjestu, mora ga propustiti. *BP2* se primjenjuje najčešće ukoliko spoznajni model procijeni da robot koji šalje upit nije dostatno ekipiran (nedostaje alat, programska podrška i sl.) ili je razina procijenjenog socijalnog kapitala u odnosu na samoprocijenu robota visoka pa se robot koji izvodi zadatak može pouzdati u kompetencije grupe.

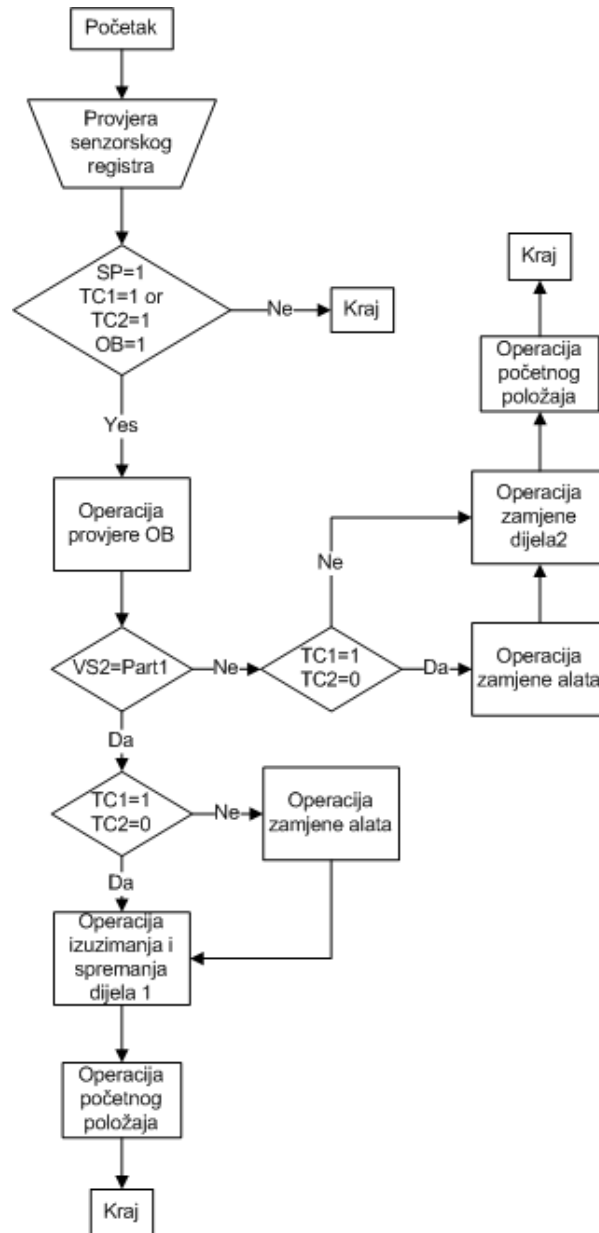
Na sljedećoj slici [Slika 5-15] prikazan je uzorak ponašanja (*BP3*) koji je kompleksniji od prethodna dva budući da se koristi prilikom operacija izuzimanja i spremanja ukoliko je objekt na nosaču dijela detektiran kao već sklopljeni proizvod. Kao što se može vidjeti iz algoritma, *BP3* sadrži operaciju promijene alata koja će biti provedena ukoliko trenutno korišteni alat nije primjenjiv za dani zadatak.

Sljedeći uzorak ponašanja (*BP4*) čiji je algoritam prikazan na [Slika 5-16], koristi se prilikom unosa novih ugradbenih elementa u sustav. *BP4* sadržava: rutinu provjere zauzetosti konvejera korištenog za unos dijelova (provjera *OB*), rutine za provjeru vrste ugradbenih elemenata na konvejeru te rutine za zamjenu alata ukoliko s trenutno korištenim (aktivnim) alatom smještnim na robotskoj ruci nije moguće izvršiti postavljeni zadatak (izuzimanje dijelova s konvejera).

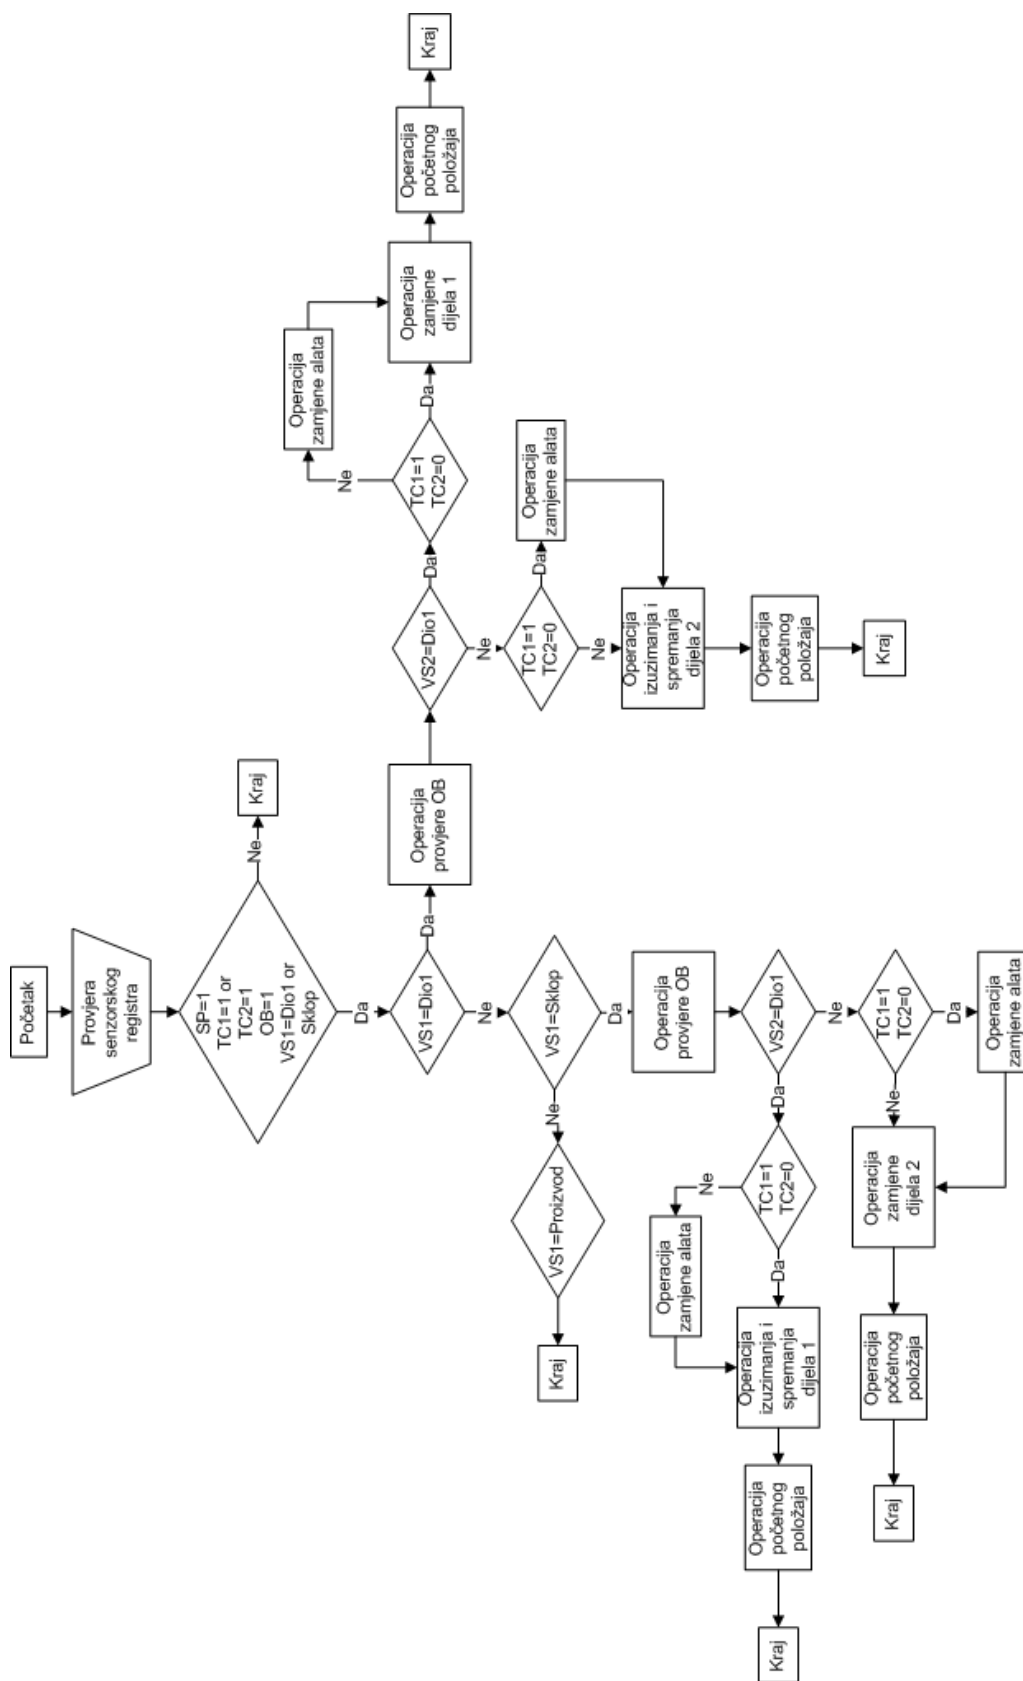
Zadnji definirani uzorak ponašanja (*BP5*) koji je po svojoj strukturi najkompleksniji, te čiji je algoritam prikazan na [Slika 5-16], koristi se prilikom operacija umetanja, odnosno sklapanja ugradbenih elemenata u sklop pa potom u gotovi proizvod. Sadrži rutine: zamjene alata, provjera stanja nosača proizvoda (*PC*) (stanje *PC-a*: prazan, pun te ako je pun nalazi li se u njemu dio, sklop ili gotovi proizvod) na zaustavnom mjestu (*SP*) i smještaj proizvoda na paletu (*P*) s gotovim proizvodima.



Slika 5-15. Algoritam trećeg uzorka ponašanja (BP3).

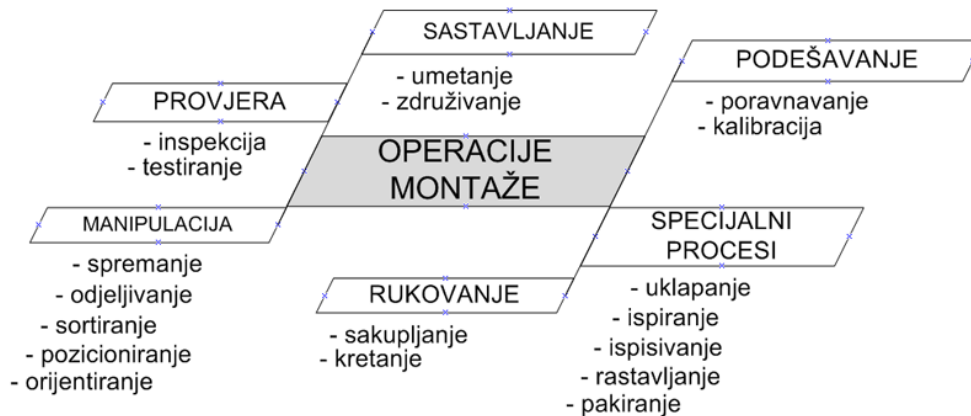


Slika 5-16. Algoritam četvrtog uzorka ponašanja (BP4).



Slika 5-17. Algoritam petog uzorka ponašanja (BP5).

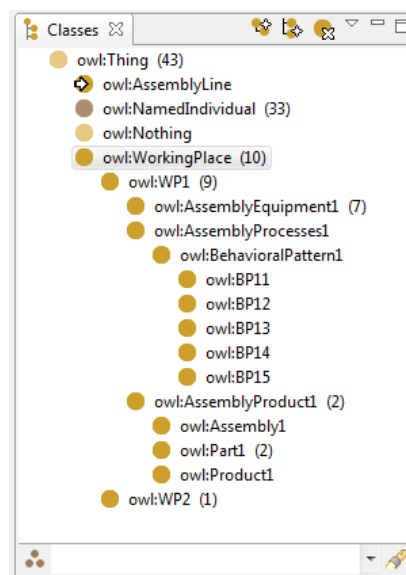
Nakon što su obuhvaćene sve sastavnice ontologije, proces razvoja uključuje definiranje taksonomije. Kako bi se sačuvala kompatibilnost s ontologijama ostalih autora koje pokrivaju područje proizvodnih djelatnosti, proces razvoja ontološke jezgre je započeo istraživanjem već postojećih ontologija. Stoga je kao podloga za razvoj odabran dio taksonomije proizvodnih djelatnosti s naglaskom na operacije sklapanja [14], koji je prikazan na slici [Slika 5-18].



Slika 5-18. Taksonomija operacije montaže.

Poštivajući strukturu prikazanu na [Slika 5-18] te imajući u vidu da taksonomija ontološke jezgre treba objediniti sve sastavnice okoline koje su značajne za sustav, osnovna podjela koja je vidljiva na slici spoznajnog modela [Slika 5-3] uključuje:

- ontologiju produkata sklapanja,
- ontologiju procesa sklapanja, te
- ontologiju opreme za sklapanje.



Slika 5-19. TopBraid Composer – hijerarhijska struktura klasa.

Slika [Slika 5-19] prikazuje hijerarhijsku strukturu definiranu *TopBraid Composer-om*. Svaka hijerarhija (ontologijsko drvo) započinje s jednom super-klasom pod nazivom *owl:Thing*. Ta klasa je predefiniрана i sve druge klase su njezine podklase. Klase u pravilu započinju prefiksom (npr. *owl:MojaKlasa*, gdje oznaka *owl* predstavlja prefiks, ali je moguće i ostaviti prefiks prazan), te velikim početnim slovom. Ukoliko se ime klase sastoji od više riječi, one se pišu zajedno s velikim početnim slovima. Recimo da želimo oblikovati neku klasu s nazivom *Assembly line* i prefixom *owl*, ta će klasa u hijerarhijskom stablu izgledati: *owl:AssemblyLine*.

Koristeći opisanu notaciju za pisanje klasa, sastavnice ontološke jezgre prikazane su u [Tablica 5-2]. Respektirajući definiciju spoznajnog modela, glavne klase radnog mjesta koje predstavlja okruženje svakog robota u grupi su:

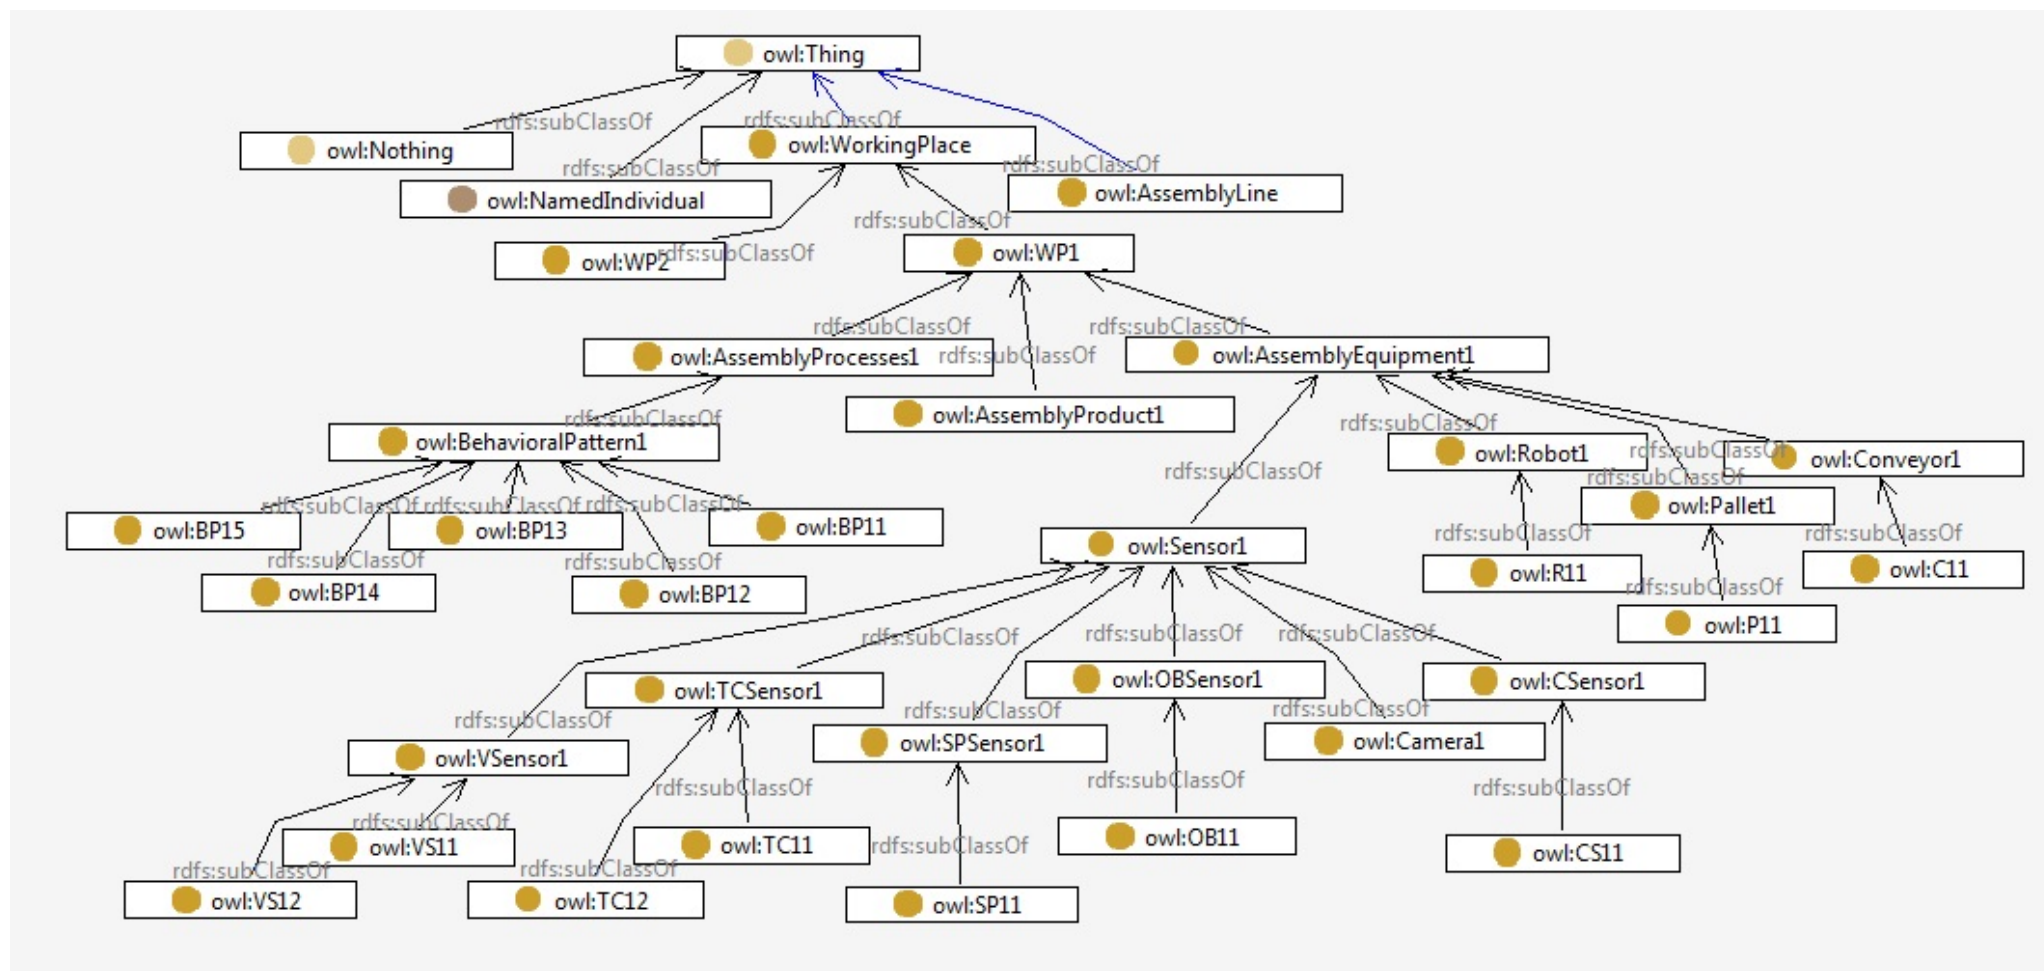
- *owl:AssemblyEquipment1*,
- *owl:AssemblyProcesses1*, i
- *owl:AssemblyProduct1*.

Moguće je zaključiti da se neke od klasa u ovom stupnju razvoja modela ne koriste prilikom donošenja odluka (npr., klasa *owl:WP2* zajedno sa svim svojim sastavnicama). Te klase su kreirane te tvore temelj za buduća istraživanja (npr., *owl:AssemblyLine*). Trenutan postav *SPARQL* upita je izveden na način da svaki agent postavlja uvijek isti upit koji je upućen *owl:WPI* klasi zajedno s osvježnim vrijednostima senzora. Budući da svaki robot za sebe postavlja upit bez obzira na ostale u grupi, odgovor spoznajnog modela unutar njegove domene ne može biti dvosmisleno interpretiran. Grafički prikaz taksonomije ontološke jezgre dan je na [Slika 5-20].

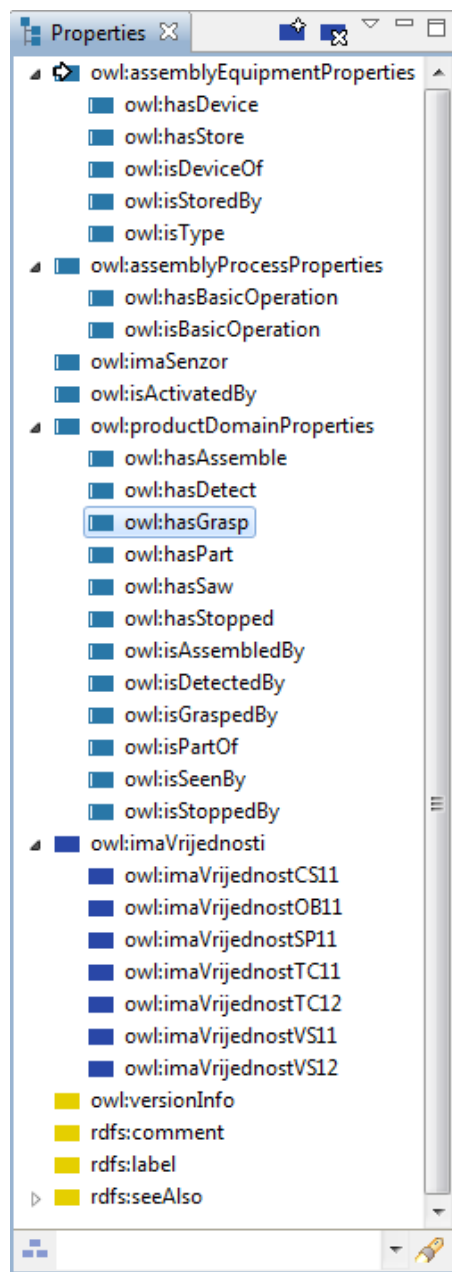
Na sličan način kao i kod klasa, slika [Slika 5-21] prikazuje svojstva (engl. *Properties*) kreirana u sklopu ontološke jezgre modela. Kako svojstva označavaju relacije između klasa i objekata unutar klasa (individua) te na taj način mogu stvarati nove klase (tzv. zaključene ili *inferred* klase), podrazumijevaju veću ili manju uporabu deskriptivne logike. Prilikom izrade rada, naglasak je postavljen na kreiranje logičkih izraza unutar *SPARQL* upita čime je omogućen pouzdan rad spoznajnog modela. U ovoj fazi razvoja tehnologije pokazalo se da pretjerana uporaba *DL* izraza unutar *OWL-a* može prouzročiti nekompatibilnosti s postojećim hardverskim komponentama što se u ovoj fazi razvoja modela željelo izbjeći.

Tablica 5-2. Taksonomija ontološke jezgre.

owl:Thing				
owl:AssemblyLine				
owl:NamedIndividual				
owl:Nothing				
owl:WorkingPlace	owl:WP1	owl:AssemblyEquipment1	owl:Conveyor1	
			owl:Pallet1	
			owl:Robot1	
			owl:Sensor1	owl:Camera1
				owl:CSensor1
				owl:OBSensor1
				owl:SPSensor1
				owl:TCSensor1
				owl:VSensor1
		owl:AssemblyProcesses1	owl:BehavioralPattern1	owl:BP11
				owl:BP12
				owl:BP13
				owl:BP14
				owl:BP15
		owl:AssemblyProduct1	owl:Assembly1	owl:Assembly11
				owl:Assembly12
			owl:Part1	owl:Part11
				owl:Part12
			owl:Product1	owl:Product11
				owl:Product12
	owl:WP2	owl:AssemblyEquipment2	owl:Conveyor2	
			owl:Pallet2	
			owl:Robot2	
			owl:Sensor2	owl:Camera2
				owl:CSensor2
				owl:OBSenso2
				owl:SPSensor2
				owl:TCSensor2
				owl:VSensor12
		owl:AssemblyProcesses2	owl:BehavioralPattern2	owl:BP21
				owl:BP22
				owl:BP23
				owl:BP24
				owl:BP25
		owl:AssemblyProduct2	owl:Assembly2	owl:Assembly21
				owl:Assembly22
			owl:Part2	owl:Part21
				owl:Part22
			owl:Product2	owl:Product21
				owl:Product22



Slika 5-20. Grafički prikaz taksonomije ontološke jezge.



Slika 5-21. TopBraid Composer – hijerarhijska struktura svojstava.

Prema [Tablica 5-1], različite vrijednosti ulaznih podataka od strane senzora trebaju rezultirati pokretanjem različitih obrazaca ponašanja. Zbog toga je bilo potrebno kreirati ontologiju koja će za točno određene vrijednosti senzora, kao odgovor vratiti jedan ili više obrazaca ponašanja. Zbog ranije navedenih slučajeva u kojima komplicirana ontologija može biti nekompatibilna s postojećim hardverom, razvijenu ontološku jezgru krase jednostavnost. Budući da je taj način do sada uvelike isproban u praksi, logički izrazi su većinom implementirani unutar *SPARQL* upita.

Kako vizijski senzor može detektirati više stanja ili objekata u okolini, kao odgovor može vratiti sljedeće vrijednosti: *false*, *product*, *part* ili *assembly*, što znači da se koriste podaci tipa

znakovni niz (engl. *string*). Ostali senzori vraćaju podatke tipa *true* ili *false*, odnosno *1* ili *0* pa su unutar ontologije ove vrijednosti postavljene kao *boolean*.

Kao što je ranije naglašeno, skoro svako svojstvo koje je dio *OWL* ontologije ima domenu (engl. *domain*) i doseg (engl. *range*). Za svojstva *owl:imaVrijednostOB11*, *owl:imaVrijednostCS11*, *owl:imaVrijednostSP11*, *owl:imaVrijednostTC11*, *owl:imaVrijednostTC12* definiran je tip podataka *boolean*. Dotična svojstva su specifična za svaki sensor respektivno (npr. svojstvo *owl:imaVrijednostCS11* ima kao domenu klasu senzora *owl:CS11*). Budući da vizijski sensor vraća vrijednost i tipa *string*, svojstvima *owl:imaVrijednostVS11* i *owl:imaVrijednostVS12* je pridjeljen pripadajući tip podataka. Sva svojstva senzora su u ontologiji postavljena kao podsvojstva svojstvu *owl:imaVrijednosti*. Slike [Slika 5-21, Slika 5-22] prikazuju *OWL* definicije navedenih senzora.


```
owl:vs11
a owl:VS11 ;
owl:imaVrijednostVS11
"product"^^xsd:string .
```

Slika 5-22. Definicija za vizijski sensor tipa *string*.

```
owl:cs11
a owl:CS11 ;
owl:imaVrijednostCS11
"true"^^xsd:boolean .
```

Slika 5-23. Definicija za kapacitivni sensor tipa *boolean*.

Iz [Tablica 5-1] je vidljivo da se *BPI* pokreće u šest slučajeva (vidljivo u tablici). Za svaki od tih slučajeva (za kombinaciju izlaza senzora koji rezultiraju *BPI* kao odzivom) napravljena je, tzv. izvedena ili zaključena (engl. *inferred*) klasa kojoj je *BPI* podklasa [Slika 5-22, Slika 5-23]. Ta izvedena klasa koja je u ontološkoj jezgri nazvana kao *Inferred1*, definirana je kao klasa (*a owl:Class*) kojoj je pridjeljeno svojstvo *owl:isActivatedBy*. Navedeno svojstvo nema čvrsto određene granice (domenu i doseg) budući da mu je domena izvedena klasa (npr., domena je *Inferred1*, a doseg neka nova izvedena klasa). Slika [Slika 5-24] prikazuje, tzv. *turtle* prikaz odnosa trojki (odnos subjekt – predikat – objekt) koji se koristi unutar *RDF-a* navedene izvedene klase.



Slika 5-24. *RDF* triple odnos.

Nova klasa, koja je u ovome slučaju nazvana *Inferred2*, definirana je ograničenjem (engl. *restriction*) koje predstavlja jedan od alata *OWL* jezika. Ta se klasa koristi prilikom povezivanja obrazaca ponašanja s vrijednostima, odnosno stanjima pojedinom senzora. Izvedena klasa *Inferred1* se sastoji od niza klasa *Inferred2* međusobno povezanih svojstvom *owl:isActivatedBy*. Svaka klasa *Inferred2* u sebi sadrži ograničenje s vrijednošću jednog od

senzora respektirajući stanja definirana unutar [Tablica 5-1] (npr., prema tablici, senzor *cs11* za *BPI* ima vrijednost *false*). Slika [Slika 5-25] prikazuje dio izvedene klase *Inferred1* koja sadržava klasu ograničenja *Inferred2*.

```

a      owl:Class ;
owl:isActivatedBy
  [ a      owl:Restriction ;
    owl:hasValue "true"^^xsd:boolean ;
    owl:onProperty owl:imaVrijednostSP11
  ] ;

```

Slika 5-25. Dio izvedene *Inferred1* klase koja sadrži ograničenje.

[Slika 5-26] prikazuje definiciju *BPI* klase u *turtle* notaciji sa svim stanjima senzora [Tablica 5-1] za prvi red u kojem se pojavljuje taj uzorak ponašanja.

```

owl:BP11
a      owl:Class ;
rdfs:subClassOf owl:BehavioralPattern1 ;
rdfs:subClassOf
  [ a      owl:Class ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean , "false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostTC11
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostSP11
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostCS11
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "assembly"^^xsd:string , "part"^^xsd:string , "false"^^xsd:string ;
        owl:onProperty owl:imaVrijednostVS11
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "false"^^xsd:string ;
        owl:onProperty owl:imaVrijednostVS12
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean , "false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostTC12
      ] ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostOB11
      ]
  ] ;

```

Slika 5-26. Klasa uzorka ponašanja *BP1* s jednom od kombinacija izlaza senzora.

Nakon što je definiranje izvedenih klasa za sve uzorke ponašanja gotovo, pristupa se definiranju *SPARQL* upita koji nakon što prenese vrijednosti stanja senzora vraća one uzorke ponašanja koji odgovaraju logičkim relacijama [Tablica 5-1]. Kao što je ranije navedeno, *SPARQL* se zasniva na izvedenim klasama s ograničenjima koje se pretražuju po principu podudaranja. Kao što je moguće vidjeti na [Slika 5-27], *SPARQL* upit se sastoji od dva glavna

dijela: od prvog dijela koji uključuje varijable (oznake senzora) te drugog dijela koji uključuje definicije izvedenih klasa u, tzv. trojnoj notaciji (*turtle*, odnosno subjekt – predikat – objekt notaciji).

```

SELECT ?Pattern ?tc1 ?tc2 ?cs1 ?ob1 ?vs1 ?vs2 ?sp1
WHERE {
  owl:tc1 owl:imaVrijednostTC11 ?tc1 .
  owl:tc2 owl:imaVrijednostTC12 ?tc2 .
  owl:cs1 owl:imaVrijednostCS11 ?cs1 .
  owl:ob1 owl:imaVrijednostOB11 ?ob1 .
  owl:vs1 owl:imaVrijednostVS11 ?vs1 .
  owl:vs2 owl:imaVrijednostVS12 ?vs2 .
  owl:sp1 owl:imaVrijednostSP11 ?sp1 .

  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?tc1 ;
      owl:onProperty owl:imaVrijednostTC11
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?ob1 ;
      owl:onProperty owl:imaVrijednostOB11
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?vs2 ;
      owl:onProperty owl:imaVrijednostVS12
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?vs1 ;
      owl:onProperty owl:imaVrijednostVS11
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?sp1 ;
      owl:onProperty owl:imaVrijednostSP11
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?tc2 ;
      owl:onProperty owl:imaVrijednostTC12
    ] .
  ?PK owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue ?cs1 ;
      owl:onProperty owl:imaVrijednostCS11
    ] .

  ?Pattern rdfs:subClassOf ?PK .
  ?Pattern rdfs:subClassOf owl:BehavioralPattern1
}

```

Slika 5-27. Struktura SPARQL upita.

Svaka trojka s ograničenjem u *SPARQL* upitu se postavlja kao objekt predikata *owl:isActivatedBy*, a subjekt je varijabla *?PK* koja predstavlja jednu od izvedenih klasa tipa *InferredI* (također, predstavlja i jednu od kombinacija izlaznih vrijednosti senzora).

Nakon što se unesu sve trojke s ograničenjima može se pristupiti ispitivanju upita. Za kreirani upit je karakteristično da se on ne mijenja budući da sadrži varijable. Mijenjaju se tek vrijednosti stanja senzora. Robot stoga jedino mora poslati ontološkoj jezgri vrijednosti senzora u obliku,

$$S_n = [TC2_n, TC1_n, CS_n, OB_n, VSI_n], \quad (17)$$

i ontološka jezgra će preuzevši vektor vrijednosti pridijeliti varijablama *SPARQL* upita. Nakon što upit bude izvršen, rezultat će predstavljati jedan ili više uzoraka ponašanja koji odgovaraju kombinaciji vrijednosti sa senzora. Slika [Slika 5-28], prikazuje jedan od mogućih odgovora ontološke jezgre ukoliko je na ulaz postavljena odgovarajuća kombinacija vrijednosti senzora.

[Pattern]	tc1	tc2	cs1	ob1	vs1	vs2	sp1
owl:BP11	B true	B false	B false	B false	S false	B false	B true
owl:BP12	B true	B false	B false	B false	S false	B false	B true

Slika 5-28. Odziv ontološke jezgre na definirani upit.

Kao što je moguće vidjeti, ova kombinacija je u tablici [Tablica 5-1] navedena unutar prvog retka. Ontološka jezgra je na temelju ovog upita kao skup rješenja ponudila izvršavanje uzoraka *BP1* i *BP2* što je u skladu s definicijama iz tablice. Nakon provedene analize svih upita utvrđeno je da su odgovori u skladu s vrijednostima definiranim unutar tablice čime je razvoj ontološke jezgre priveden kraju.

Detaljan ispis *OWL* kodova definicija za uzorke ponašanja se nalazi u *Prilogu A*.

5.7. Zaključivanje temeljeno na Bayesovoj mreži

U sociologiji, pojam “socijalni kapital” označava očekivani zajednički benefit proizašao iz kooperacije među individuama i/ili grupama. Iako različite socijalne znanosti naglašavaju različite aspekte socijalnog kapitala, zajednička misao im je da “socijalni odnosi donose dodatnu vrijednost”. Ta vrijednost koja je ostvarena kroz socijalne kontakte, očituje se u povećanju produktivnosti. Referenca [32] definira socijalni kapital kao zajednički socijalni resurs koji olakšava razmjenu informacija, dijeljenje znanja te izgradnju znanja kroz stalnu interakciju, izgrađenu na povjerenju i održavanu kroz uzajamno razumijevanje. Trenutna istraživanja sugeriraju da ne postoji jedan put ka ostvarivanje socijalnog kapitala, već da se tu radi o zajedničkom djelovanju više varijabli koje je moguće interpretirati jednu po jednu [33]. Pokazalo se da je prilikom kreiranja socijalnog kapitala posebno važna kontinuirana i pozitivna interakcija. Pozitivna interakcija omogućuje stvaranje dodatnih vrijednosti, posebno kada je izgrađena na pozitivnim stavovima i idejama individua ili grupa unutar zajednice [97, 98]. Ona omogućuje identificiranje zajedničkih ciljeva, ostvarivanje zajedničkog razumijevanja i socijalnih protokola, te izgradnju povjerenja [99].

Na ostvarivanju socijalnih osobina kod umjetnih tvorevina kao što su roboti se danas jako puno radi. Primjena metodologija umjetne inteligencije kod grupa robota uključuje isticanje socijalnih komponenti po uzoru na živa bića i to kroz učenje, adaptaciju, evoluciju,

inteligentnu kontrolu, svjesnost konteksta okoline, itd. Bayesove mreže se sve više koriste za razumijevanja i simuliranje prirodnih zakonitosti unutar različitih domena interesa.

U sklopu ovog rada, kontekstualne informacije (spoznaje, iskustva, vjerovanja i sl.) pohranjene su unutar Bayesove mreže kako bi odgovorile na izazove prirodno neuređene okoline. Razvoj mreže inspiriran je fenomenom socijalnog kapitala na način da se odluke robota unutar grupe temelje na vjerovanjima u kompetencije i sposobnosti ostalih robota u grupi. Navedene informacije mreži donosi stručnjak unoseći dokaze, odnosno svoje procijene karakteristika promatrane grupe (homogenost, ekipiranost, kompetencije, implementiranu programsku podršku, stanje opreme i sl.). Baš kao što odluke pojedinca-osobe unutar neke ljudske zajednice najčešće ovise o spoznajama, vjerovanjima i povjerenju u grupu kojoj pripada, tako i robot svoje odluke može temeljiti na ranije definiranim spoznajama, vjerovanjima i procjenama. Prilikom razvoja mreže korištene su spoznaje ostvarene u sklopu ranije provedenog istraživanja razvoja Bayesove mreže kod različitih ljudskih zajednica [84].

Budući da kontekstualna spoznaja (engl. *Contextual Awareness*) kao pojam spada unutar ere sveprisutnog računarstva, Bayesova mreža je razvijena u skladu s njenom vizijom jer svoje odluke temelji na kontekstu, odnosno spoznajama koje opisuje domenu robotskog djelovanja.

Ontološka jezgra spoznajnog modela kao odziv na trenutno stanje okoline robotu nudi jedno ili više rješenja u vidu uzoraka ponašanja unutar kojih su definirane akcije robota. Budući da poštuje pretpostavku otvorenog svijeta (engl. *Open World Assumption*) [100], ontologije po svojoj definiciji ne mogu svaki puta polučiti jedinstveno rješenje za dano stanje okoline. U tome slučaju, robot uz pomoć Bayesove mreže donosi odluku o pokretanju jednog uzorka ponašanja kao jedinstvenog rješenja. U slučaju da je unutar Bayesove mreže grupa ocijenjena kao nekompetentna za obavljanje nekog kompleksnijeg zadatka, ako može, robot će taj zadatak radije napraviti sam, nego ga proslijediti sljedećem u grupi.

Iako se inicijalne vjerojatnosti za Bayesovu mrežu mogu prikupljati koristeći različite tehnike iz domene umjetne inteligencije (npr. rudarenjem podataka što često zahtjeva duži vremenski period potreban za prikupljanje i obradu informacija), u sklopu ovog rada korištena je posebna tehnika temeljena na evaluaciji snage veza, odnosno utjecaja između varijabli Bayesove mreže (utjecaj veza između čvora roditelja i čvora djeteta). Taj pristup se pokazao posebno prikladan budući da ne postoje empirijski podaci vezani za vrijednosti vjerojatnosti kod varijabli koje mogu utjecati na stvaranje svijesti o socijalnom kapitalu kod grupe robota [101].

5.7.1. Topologija Bayesove mreže

Prvi korak u razvoju Bayesove mreže odnosi se na određivanje varijabli – čvorova. Kao što je ranije naglašeno, postoji puno parametara koji mogu biti uzeti u razmatranje prilikom karakterizacije značenja socijalnog kapitala kod ljudskih zajednica. Na temelju reference [84] u sklopu koje su autori proveli sintezu značajnih varijabli za kreiranje modela Bayesove mreže koja opisuje socijalni kapital kod ljudskih zajednica, sljedeća tablica [Tablica 5-3] sadržava varijable koje su identificirane, prilagođene, nadopunjene te implementirane u Bayesovu mrežu koja upravlja odlukama robota u grupi u sklopu ovog rada. Pristup u kojem robot u grupi donosi odluke samoprocjenom te procjenjujući socijalni kapital grupe predstavlja jedinstveno, odnosno originalno rješenje.

Tablica 5-3. *Varijable Bayesove mreže s pripadajućim stanjima.*

Ime varijable	Stanje varijable
Attitude	Positive/Negative
Interactions	Positive/Negative
Shared Understanding	High/Low
Origin Awareness	Present/Absent
Competence Awareness	Present/Absent
Capability Awareness	Present/Absent
Trust	High/Low
Social Capital	High/Low
Self Assessment	Competent/Incompetent

U nastavku su dane definicije za svaku identificiranu varijablu Bayesove mreže:

- **Stav (engl. *Attitude*)** – generalni stav o stanju sustava u cjelini. Sastoji se od, tzv. *a priori* vjerojatnosti i predstavlja subjektivno vjerovanje ljudskog stručnjaka o dotrajalosti opreme, sklonosti grupe robota prema kvarovima i sl.,
- **Interakcije (engl. *Interactions*)** - temelj socijalnog kapitala. Ova varijabla iskazuje subjektivno vjerovanje stručnjaka u mogućnosti grupe da međusobno komunicira, odnosno obavlja zajedničke poslove (vjerovanje u zajedničkog djelovanja ili kooperacije),
- **Zajedničko razumijevanje (engl. *Shared Understanding*)** – dolazi od činjenice da roboti dijele istu ontološku bazu znanja. Kroz ovu varijablu je iskazan potencijal pojedinog robota u grupi da koristi zajedničku bazu znanja. Proizlazi iz pripremljenosti softverskih i hardverskih komponenti za komunikaciju s ontološkom bazom,

- **Porijeklo (engl. *Origin Awareness*)** – uzima u obzir pretpostavku da je veća vjerojatnost da su roboti u grupi kompatibilni za zajednički rad ako su od istog proizvođača (iste ili slične komunikacijske rutine, iste ili slične hardverske i softverske komponente i sl.),
- **Kompetencije (engl. *Competence Awareness*)** – odražava vjerovanje stručnjaka u kompetencije, odnosno vještine grupe robota u cjelini za obavljanje danog zadatka. Proizlazi iz sličnosti robotskih arhitektura, mogućnosti korištenja svih potrebnih alata (treba li robot zrak pod pritiskom i je li on dostupan svim robotima u grupi i sl.), itd.
- **Sposobnost (engl. *Capability Awareness*)** – izražava opće vjerovanje stručnjaka u sposobnosti robota u grupi da izvode sve programske strukture (da bi robot izvršio pojedini uzorak ponašanja on mu kao računalni program mora biti dostupan, npr. u memoriji), da su mu dostupni svi potrebni alati i sl.
- **Povjerenje (engl. *Trust*)** – subjektivni nivo sigurnosti ili povjerenja stručnjaka u grupu robota u cjelini da može zajednički raditi prilikom obavljanja zadanih poslova. Proizlazi iz toga koliko kvalitetno je konstruiran, sklopljen i komunikacijski povezan cijeli postav.
- **Socijalni kapital (engl. *Social Capital*)** – generirana vrijednost koja ocjenjuje grupu u cjelini. Odabir uzoraka ponašanja se vrši na temelju procijenjenog zajedničkog benefita proizašlog iz zajedničkog rada grupe robota na zadanim poslovima.
- **Samoprocjena (engl. *Self Assessment*)** – težinski faktor (engl. *bias*) koji predstavlja vjerovanje robota u vlastite kompetencije i sposobnosti u ovisnosti o svima mogućim zadacima. Ako je (samo)procjena robota od strane stručnjaka negativna robot će vjerovati da je kompetentan za izvršavanje manje kompleksnih uzoraka ponašanja.

Ocjenjujući utjecaje među definiranim varijablama, stručnjak utječe na ponašanje mreže. Na taj se način generira potencijal grupe da zajednički radi na danom problem u vidu varijable *Social Capital*. Kao protuteža (protutuutjecaj), u mrežu je uvedena varijabla *Self Assessment*, koja je suprotstavljena vrijednosti (protutuuteg) varijabli *Social Capital*. U slučaju da je socijalni kapital ocijenjen relativno nisko, te da promatrani robot iz nekog razloga nije u stanju izvršiti postavljene zadatke, varijabla *Self Assessment* će utjecati na njegovu odluku da se pouzda u kompetencije grupe.

Na temelju procjena, odnosno subjektivnih vjerovanja stručnjaka, mreža generira vrijednosti koje označavaju socijalni kapital. Snaga utjecaja ($S+$, $M+$, $W+$) između varijabli roditelja (*Social Capital* i *Self Assessment*) te varijabli djece (uzorci ponašanja - BN_1, \dots, BN_5)

određuje se procjenom složenosti uzorka ponašanja. Definicije svih pet uzoraka ponašanja iz kojeg je moguće okarakterizirati stupnjeve kompleksnosti na nalaze se u sklopu poglavlja *Ontološka jezgra modela*.

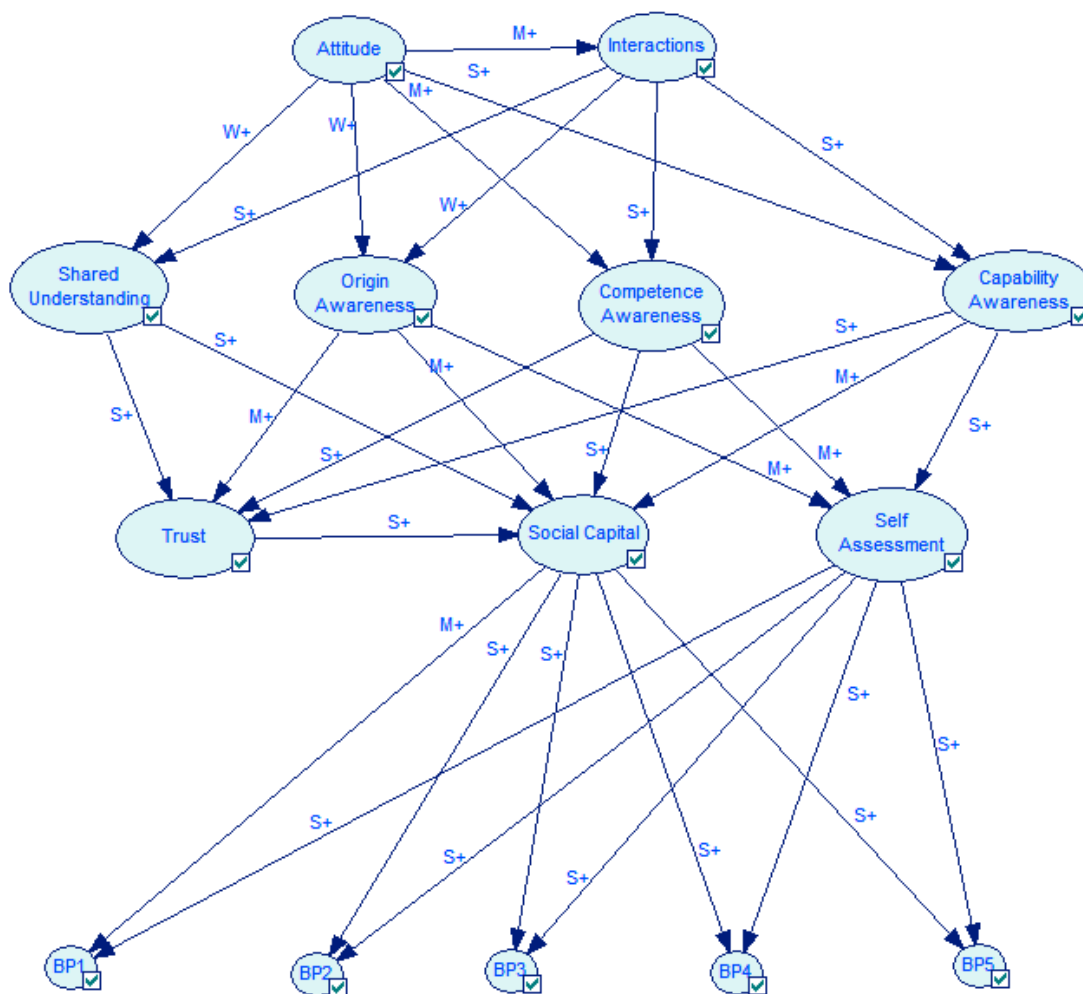
U slučaju da je uzorak ponašanja kompleksan, odnosno da za njegovo izvršavanje robot mora koristiti različite alate i senzore, bit će potrebna veća razina kompetencije robota te će veze varijabli roditelja biti ocijenjene u skladu s time. Sljedeća tablica [Tablica 5-4] prikazuje inicijalno definirane utjecaje varijabli roditelja u ovisnosti o promatranim uzorcima ponašanja.

Tablica 5-4. *Inicijalni postav utjecaja varijabli roditelja na varijable BP_n.*

Uzorak ponašanja	Snaga utjecaja	
	<i>Social Capital</i>	<i>Self Assessment</i>
<i>BP1</i>	<i>M+</i>	<i>S+</i>
<i>BP2</i>	<i>S+</i>	<i>S+</i>
<i>BP3</i>	<i>S+</i>	<i>S+</i>
<i>BP4</i>	<i>S+</i>	<i>S+</i>
<i>BP5</i>	<i>S+</i>	<i>S+</i>

Uzorci ponašanja se međusobno razlikuju po svojoj strukturi i kompleksnosti. Dok su uzorci ponašanja nižeg rednog broja (*BP1*, *BP2*) manje kompleksni, odnosno zahtijevaju samo odluke propuštanja, tj. zaustavljanja palete na radnom mjestu, uzorci ponašanja višeg rednog broja su kompleksniji te njih može obavljati samo potpuno ekipiran robot koji sadržava sve informacije te hardverske i softverske komponente.

Modeliranje Bayesove mreže je provedeno prema postupku opisanom u sklopu četvrtog poglavlja [Slika 4-5]. Postupak je iterativan te uključuje stalne evaluacije mreže prilikom razvoja. Izgled strukture modela (topologija mreže) utemeljen je na trenutnim istraživanjima vezanim za socijalni kapital kod ljudskih zajednica. Navedena istraživanja se temelje na kvalitativnim zaključivanjima pojedinaca, odnosno fokus je postavljen na to kako pojedinci ili grupe gledaju i shvaćaju svijet oko sebe te oblikuju značenja izvan svojih iskustava [102]. Unutar ovog rada izvršena je promijena topologije i varijabli mreže tako da se nova mreža može koristiti prilikom donošenja odluka temeljenih na socijalnom kapitalu i samoprocijeni kod grupe robota. Uzročni odnosi među varijablama su pretpostavljeni i postavljeni u aciklički graf tako da odražavaju snagu i smjer međusobnih utjecaja što je vidljivo iz smjera strelica. Na taj je način dodatno definiran utjecaj pojedine varijable roditelja na varijablu dijete čime je omogućeno olakšano definiranje početnih utjecaja.



Slika 5-29. Inicijalni model Bayesove mreže socijalnog kapitala kod grupe robota.

Nakon što su u prvom koraku definirane varijable, u drugom koraku te su varijable smještene u grafičku strukturu u ovisnosti o utjecajima varijabli jedne na drugu. Prethodna slika [Slika 5-29] prikazuje početnu verziju Bayesove mreže čiji su težinski faktori do finalne verzije višestruko korigirani.

Kao što je moguće vidjeti, utjecaji varijabli jedne na drugu prikazani su s *roditelj-dijete* odnosima. Tako je varijabla *Trust* je u isto vrijeme dijete od *Shared Understanding* te različitih vrsta svjesnosti (*Origin Awareness*, *Competence Awareness*, *Capability Awareness*). Također, varijable roditelji koji u tome slučaju predstavljaju pretke, imaju utjecaj i na ostale varijable u ovisnosti o postavljenim vezama (linkovima).

U Bayesovoj mreži, svaka varijabla, odnosno stanje te varijable zahtjeva definiranje početnih vjerojatnosti koje predstavljaju određene hipoteze o samoj varijabli. Najčešće su te vjerojatnosti dobivene uz pomoć znanja stručnjaka o onome što ta varijabla predstavlja. Određivanje vrijednosti vjerojatnosti može biti poprilično teško i leži u samom srcu problema Bayesovog zaključivanja. U pristupu koji je korišten u ovome radu, uvjetne vjerojatnosti su

izračunate tako što su uzeti u obzir kvalitativni opisi odnosa među varijablama [84]. Svaka vrijednost vjerojatnosti kroz linkove istovremeno opisuje i snagu odnosa s ostalim varijablama. Slova *S* (*Strong*), *M* (*Medium*) i *W* (*Weak*) predstavljaju različite stupnjeve utjecaja. Svaki stupanj utjecaja ima svoju vrijednost praga koja je prikazana u [Tablica 5-5]. Znakovi “+” i “-“ predstavljaju pozitivne i negativne odnose. Vrijednosti uvjetnih vjerojatnosti su dobivene tako što su težinski faktori dodavani na vrijednost varijabli u ovisnosti o broju roditelja i snazi odnosa između roditelja i djeteta. Tako na primjer, *Attitudes* i *Interaction* imaju pozitivni i jaki (*S+*) utjecaj na *Origin Awareness*. Dokaz o pozitivnom stavu će proizvesti vrijednost uvjetne vjerojatnosti za *Origin Awareness* od 0.98 (vrijednost praga za *Strong* je 0.98). Sljedeća formula prikazuje način izračuna težinskih faktora:

$$WF = \left(TV - \frac{1}{NS} \right) / NP, \tag{18}$$

gdje je:

- *WF* – težinski faktor (engl. *Weight Factor*),
- *TV* – vrijednost praga (engl. *Threshold Value*),
- *NS* – broj stanja koja varijabla može poprimiti (engl. *Number of States*),
- *NP* – broj roditelja (engl. *Number of Parents*).

Tako će za varijablu *Origin Awareness* koja ima dva roditelja težinski faktor iznositi 0.24. Sljedeća tablica prikazuje izračune i vrijednosti težinskih faktora za čvorove (varijable) s dva roditelja.

Tablica 5-5. Vrijednosti praga i težinskih faktora za dva roditelja.

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Budući da nesigurnost postoji, kod određivanje praga postavljena je varijabla α pomoću koje je moguće utjecati i na taj aspekt. Te vrijednosti je moguće u kasnijoj fazi mreže podesiti u slučaju da se pojave nove informacije koje opisuju odnose među varijablama. *Prilog B.* sadržava tablice s izračunima vrijednosti pragova i težinskih faktora za jednog, dva, tri, četiri i pet roditelja.

Koristeći ovaj pristup moguće je generirati tablice uvjetnih vjerojatnosti (engl. *Conditional Probability Table - CPT*) za svaki čvor (varijablu) bez obzira na broj roditelja ili kako je inicijalno (*a priori*) znanje uvedeno u mrežu.

5.7.2. *Izračun tablica uvjetnih vjerojatnosti*

U sklopu ove točke bit će opisan postupak izračuna tablice uvjetnih vjerojatnosti za jedan čvor (*Origin Awareness*). Budući da je postupak izračuna tablica uvjetnih vjerojatnosti za sve čvorove istovjetan, ostale tablice zajedno s pripadajućim detaljnim izračunima su smještene u *Prilog C*.

Prateći strukturu Bayesove mreže moguće je vidjeti pozitivni i slab utjecaj dva roditelja (*Attitude* i *Interactions*) na čvor *Origin Awareness* [Slika 5-17]. Kombinirajući Bayesovo pravilo koje je ranije opisano u sklopu disertacije (četvrto poglavlje) s težinskim faktorima navedenim unutar [Tablica 5-5], početne vjerojatnosti za ovu varijablu su izračunate kako slijedi:

- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 + 0.15 = 0.7,$
- $P(\text{OriginAwareness} = \text{low} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 1 - 0.7 = 0.3,$
- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 0.5 + 0.05 = 0.55,$
- $P(\text{OriginAwareness} = \text{low} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 1 - 0.55 = 0.45,$
- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 0.5 + 0.15 = 0.65,$
- $P(\text{OriginAwareness} = \text{low} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 1 - 0.65 = 0.35,$
- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.5,$
- $P(\text{OriginAwareness} = \text{low} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 1 - 0.5 = 0.5.$

U slučaju da neke vrijednosti za uvjetne vjerojatnosti ne odgovaraju stvarnom stanju, na preporuku stručnjaka za domenu interesa moguće je u tablicu unijeti i druge vrijednosti. Ako se pogleda primjer u kojem prema unesenim težinskim faktorima te izračunu izlazi:

- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.5,$

može se zaključiti da je za taj slučaj potrebna intervencija budući da bi očekivana vrijednost trebala biti barem približna suprotnoj:

- $P(\text{OriginAwareness} = \text{high} / \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 + 0.15 = 0.7$.

Tako su u CPT unesene nove vrijednosti:

- $P(\text{OriginAwareness} = \text{high} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.3$,
- $P(\text{OriginAwareness} = \text{low} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.7$.

Slične intervencije stručnjaka provedene su kod ostalih tablica uvjetnih vjerojatnosti. Tablica [Tablica 5-6] prikazuje CPT za varijablu *Origin Awareness* koja ima dva roditelja.

Tablica 5-6. Tablica uvjetnih vjerojatnosti za čvor *Origin Awareness*.

	<i>Attitude</i>	<i>positive</i>		<i>negative</i>		
		<i>Interactions</i>	<i>Positive</i>	<i>negative</i>	<i>positive</i>	<i>negative</i>
Origin Awareness	<i>High</i>		0.7	0.55	0.65	0.3
	<i>Low</i>		0.3	0.45	0.35	0.7

Izračun ostalih tablica uvjetnih vjerojatnosti zajedno s pripadajućim izračunima dostupan je u *Prilogu 2*.

5.7.3. Postavljanje upita Bayesovoj mreži

Kao što je ranije navedeno, mehanizmi za donošenje odluka u Bayesovim mrežama temelje se na prostiranju utjecaja nakon što se u mrežu unesu novi dokazi. Unošenjem dokaza (sigurnih događaja) mijenjaju se vjerojatnosti, odnosno vjerovanja u ovisnosti o utjecajima (topologiji mreže) i kod ostalih varijabli. Jedan način za postavljanje upita mreži je da se razvije više mogućih i vjerojatnih scenarija [103]. Istraživanje navedeno u referenci je pokazalo da ljudi žele interpretirati i objasniti bilo koju socijalnu situaciju ocjenjujući i tražeći najvjerojatnije scenarije da bi testirali i razumjeli socijalne fenomene. Isti princip je korišten prilikom donošenja odluka za robota unutar grupe. U fazi implementacije spoznajnog modela te na temelju scenarija koji najbolje opisuje stanje zatečeno unutar domene od interesa, stručnjak sustava u Bayesovu mrežu unosi dokaze. Za vrijeme rada, robot najprije konzultira spoznajni model čija ontološka jezgra nudi svoj skup uzoraka ponašanja koji predstavljaju moguća rješenja na trenutno stanje. Bayesova mreža potom na temelju vrijednosti procijenjenog socijalnog kapitala i respektirajući vjerovanje u svoje kompetencije (varijabla

Self Assessment), odlučuje o odabiru jednog uzorka ponašanja. U slučaju da je vrijednost socijalnog kapitala evaluirana od strane mreže kao relativno visoka, a sposobnost u vlastite kompetencije niska, cilj je da robot odabere manje kompleksan zadatak (uzorak ponašanja) te s povjerenjem prepustiti kompleksniji posao sljedećem robotu.

Upit (engl. *Query*) koji ontološka jezgra prosljeđuje Bayesovoj mreži sadrži sljedeće podatke (dokaze):

- popis uzoraka ponašanja BN koje je ontološka jezgra ponudila kao rješenje na trenutno stanje u okolini u formi $BN = [BN_1, BN_2, \dots, BN_5]$ gdje vrijednosti za BN mogu biti 0 ili 1 u ovisnosti je li ontološka jezgra kao rješenje ponudila ili nije navedeni uzorak ponašanja,
- vrijednost *Self Assessment* varijable koja je jedinstvena za svakog robota i predstavlja težinsku vrijednost (engl. *bias*) koja uz varijablu *Social Capital* ima utjecaj na konačan odabir uzorka ponašanja. U slučaju da ta informacija nije poznata upit šalje nulu koja označava da za tu varijablu ne postoji dokaz trenutnog stanja.

Konačan izgled upita Bayesovoj mreži dan je sljedećim izrazom:

- $Query = [[0/1, 0/1, 0/1, 0/1, 0/1], 0/Competent/Incompetent]$.

Bayesova mreža kao odgovor vraća oznaku odabranog uzorka ponašanja kojeg potom robot izvršava. U slučaju da ontološka jezgra ponudi samo jedan uzorak ponašanja znači da je to rješenje jedinstveno te nije potrebna intervencija Bayesove mreže.

5.7.4. *Primjeri scenarija*

Osvježavanje podataka mreže, u kojoj su definirani od ranije razrađeni scenariji, može se koristiti prilikom razumijevanja odnosa varijabli (na primjer, ako je pacijent muško ne može biti trudan) [104]. Razvoj scenarija nije temeljen na formalnoj eksperimentalnoj studiji, već su odabrana tri različita i dijametralno suprotna scenarija. U prvom dijelu, mreža je razvijena koristeći najprije prvi scenarij. Postupak je uključivao ispravke vrijednosti uvjetnih vjerojatnosti čvorova na temelju promijena inicijalno postavljenih utjecajnih faktora. Nakon toga je u sklopu šestog poglavlja ispitan rad i skalabilnost razvijenog modela kroz preostala dva scenarija. Za ispitivanje mreže u realnim uvjetima, stručnjak može prilagoditi podatke te unijeti dokaze o stvarnom stanju mreže (dokaze o karakteristikama mreže). Razvojem i evaluacijom mreže kroz scenarije, analiza je omogućila podešavanje težinskih faktora “u hodu” čime je model postao robusniji.

Scenarij 1.

Grupa A sadrži četiri robota različitih proizvođača. Budući da se radi o starijoj opremi (linija za sklapanje, roboti), subjektivna ocjena stručnjaka za projektiranje proizvodnih robotskih sustava u stanje promatrane grupe robota je vrlo slaba. Roboti posjeduju mrežnu opremu i svu softversku podršku te su u stanju razmjenjivati poruke i spajati se na centralni poslužitelj gdje je smješten spoznajni model. Zbog nestručno postavljene linije za sklapanje, subjektivno povjerenje stručnjaka u točnost izvođenja robotskih operacija je niska. Samo dva od četiri robota su dostatno ekipirana da mogu obavljati sve operacije (nedostaju alati, jednom nedostaje vizijski senzor).

Scenarij 2.

Grupa B sadrži tri nova robota koje je napravio isti proizvođač. Svi roboti sadržavaju sve komponente (komunikacijske, hardverske i softverske) da bi međusobno mogli komunicirati i obavljati sve potrebne zadatke koji su zahtijevani prilikom sklapanja proizvoda. Sigurnost stručnjaka u sposobnosti sustava je visoka.

Scenarij 3.

Grupa C sadrži tri nova robota koje su napravili različiti proizvođači. Svi roboti sadrže svu komunikacijsku i softversku podršku, no jedan ne sadrži svu programsku podršku potrebnu za izvođenje robotskih akcija (uzoraka ponašanja). Svi roboti posjeduju sve potrebne alate te su dostatno ekipirani. Budući da je sustav nov i nije ispitan, povjerenje stručnjaka u rad grupe robota je relativno nisko.

5.7.5. Razvoj mreže i podešavanje parametara

Za razvoj Bayesove mreže te podešavanja pripadajućih parametara korišten je prvi opisani scenarij. U šestoj cjelini ovog rada je potom izvršena validacija i verifikacija dobivenih težinskih faktora koristeći preostale scenarije. Ispitivanje na ovaj način je u skladu s procesom evolucije mreže [Slika 4-5] koji vodi ka finalnoj inačici.

Unutar opisa prvog scenarija moguće je iščitati sljedeće vrijednosti varijabli mreže:

- *Shared Understanding = high; Origin Awareness = absent; Capability Awareness = absent; za dva od četiri robota vrijedi Self Assessment = incompetent.*

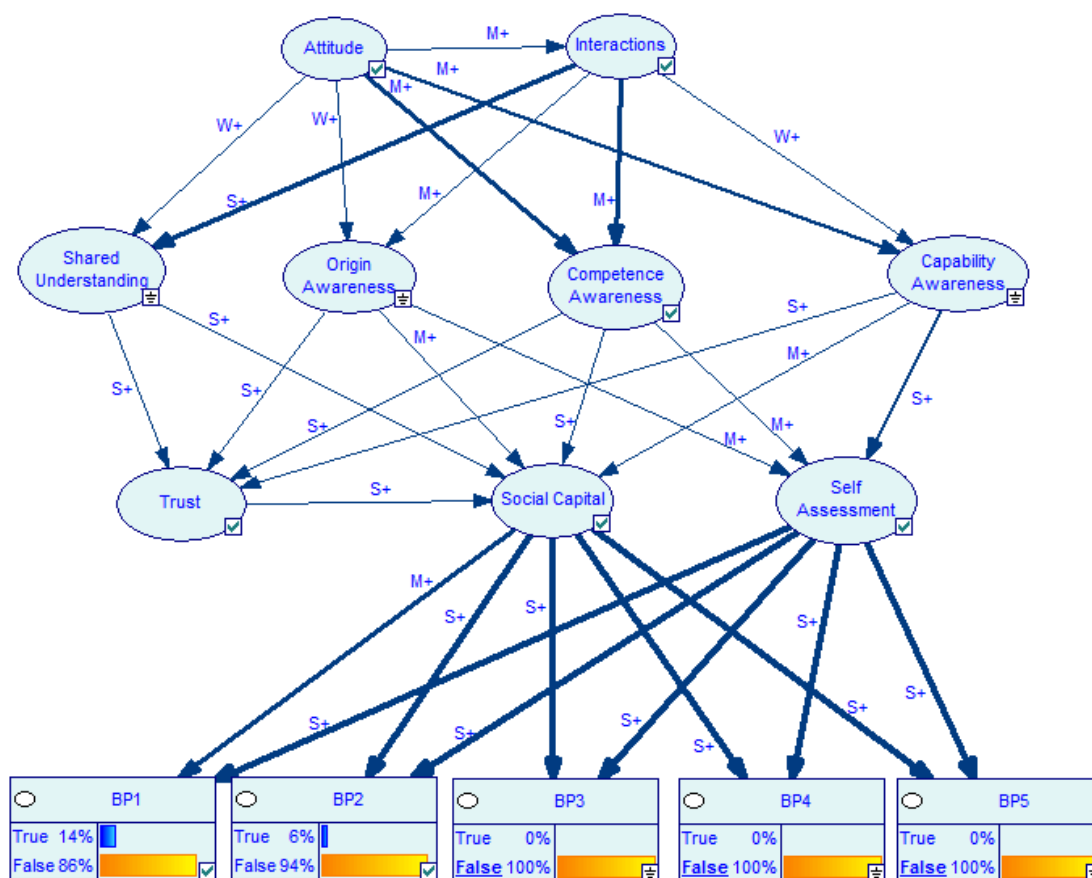
Kao što je moguće vidjeti, mreži nije potrebno dati sve informacije već samo sigurne događaje (dokaze). Na taj se način omogućuje širenje utjecaja kroz mrežu budući da se sve varijable koje ne sadrže dokaz procjenjuju na temelju ugrađenih vjerovanja (pojam *d-separacije* opisan u četvrtom poglavlju). Nakon što su dokazi uvedeni, provedena je analiza u

sklopu koje se na ulaz Bayesove mreže dovodi pet mogućih kombinacije uzoraka ponašanja. Navedene kombinacije definirane u [Tablica 5-1], predstavljaju moguće odzive ontološke jezgre (taksonomija + logičko zaključivanje) u ovisnosti o stanjima senzora u sveprisutnoj (engl. *ubiquitous*) okolini. U slučaju da ontološka jezgra ponudi kao rješenje samo jedan uzorak ponašanja, zaključivanje pomoću Bayesove mreže se ne izvodi.

Sljedeća slika [Slika 5-30] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

- $Query = [[1, 1, 0, 0, 0], 0]$,

koji sugerira mreži odabir *BP1* ili *BP2* kao rješenja na trenutno stanje u okolini.



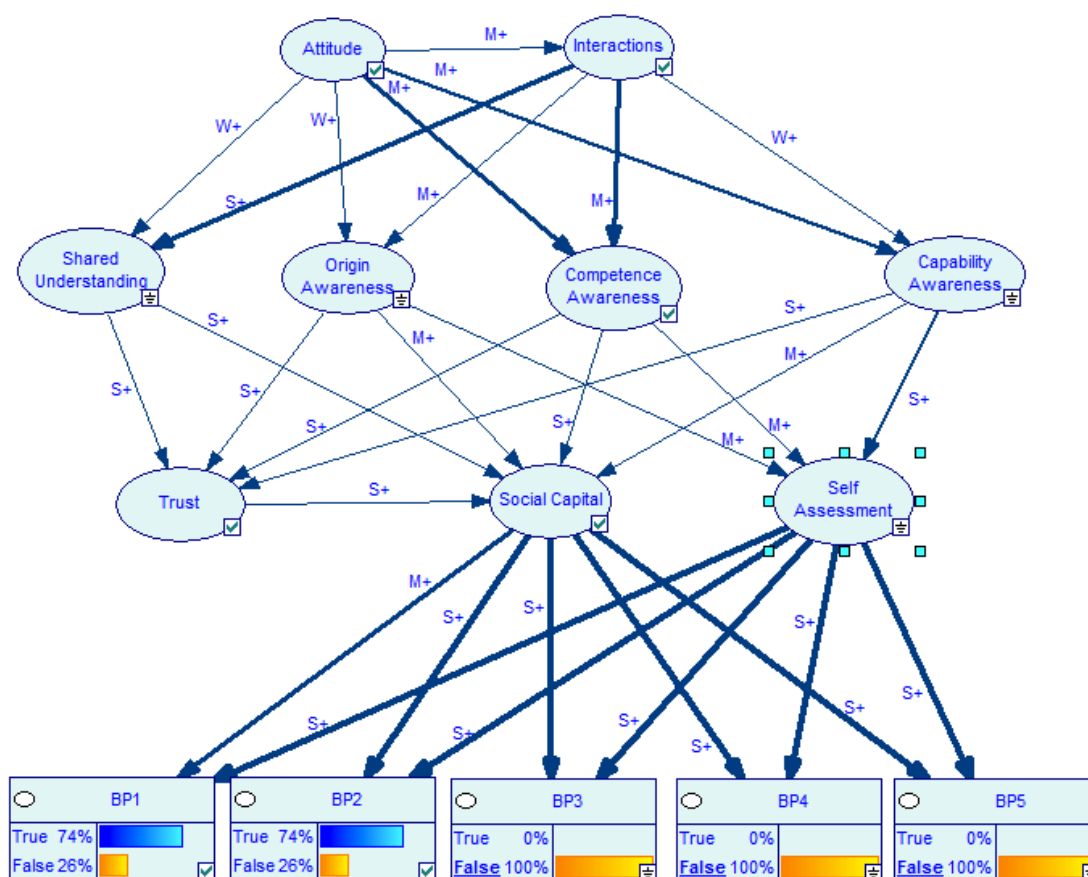
Slika 5-30. Razvoj mreže – prvi scenarij, odluka za BP1 ili BP2, 0.

Debljina linija (veza) označava snagu prostiranja utjecaja među varijablama kroz mrežu. Korišteni prikaz je jako koristan budući da omogućuje lakše iterativno modeliranje mreže pa dozvoljava stručnjaku da po potrebi korigira težinske faktore u ovisnosti o željenim odzivima. Navedeni alat koji se naziva “*snaga utjecaja*” (engl. *Strenght of influence*) dostupan je unutar *Genie* softvera te se kao takav koristi prilikom razvoja i evaluacije Bayesovih mreža. Slika prikazuje stanje u kojem nije unesen dokaz o kompetencijama robota koji trenutno šalje upit. Na temelju dostupnih informacija, Bayesova mreža sugerira izvršavanje *BP1*, odnosno zadržavanje dijela na radnom mjestu. To bi značilo da mreža vjeruje da je robot dovoljno

kompetentan da samostalno nastavi raditi čim se za to ostvare uvjeti (npr., promijeni se stanje senzora na radnom mjestu i sl.). Budući da prema definiranom scenariju u grupi postoje roboti koji nisu dovoljno ekipirani za sve poslove, bilo bi bolje da je odabran uzorak ponašanja *BP2* koji sugerira propuštanje nosača proizvoda (*PC*) do sljedećeg robota. Time bi se mreža pouzdala u sljedećeg robota za kojeg bi se možda znalo stanje ekipiranosti. Ako su sljedećim upitom:

- $Query = [[1, 1, 0, 0, 0], competent]$,

mreži uneseni dokazi o kompetentnosti robota, mreža *NEĆE* ponuditi jedinstveno rješenje [Slika 5-31] što se može shvatiti kao indikator neispravnog rada.



Slika 5-31. Razvoj – prvi scenarij, odluka za BP1 ili BP2, kompetent.

Ova razmatranja sugeriraju da je potrebno izvršiti korekciju težinskih faktora. Razlog zašto je to tako leži u činjenici da su utjecaji varijabli *Social Capital* i *Self Assessment* na varijable uzoraka ponašanja podešeni pogrešno, odnosno nedovoljno detaljno. Ideja je da se u ovisnosti o stupnju kompleksnosti uzoraka ponašanja zajedno s varijablama utjecaja (*S+*, *M+*, *W+*) naglase utjecaji pojedinih varijabli roditelja. Tako se prema definiciji (peto poglavlje), uzorak ponašanja *BP1* koristi da bi se nakon provjere stanja senzora donijela odluka o čekanju, odnosno zadržavanju nosača proizvoda (*PC*) na promatranom radnom mjestu. Ta

odluka “sugerira” određeni stupanj “povjerenja” robota u svoje kompetencije da će biti u stanju izvršiti sljedeći zadatak (kompleksniji uzorak ponašanja) kada se stvore odgovarajući uvjeti. Uzevši u obzir navedeno razmišljanje, korigirane vrijednosti utjecaja varijabli *Social Capital* i *Self Assessment* su postavljene na “*W+*” i “*S+*”, respektivno. Drugi uzorak ponašanja (*BP2*) predstavlja akciju u sklopu koje robot oslobađa i propušta nosač proizvoda (*PC*) do sljedećeg radnog mjesta što ukazuje na vjerovanje u kompetencije grupe (*Social Capital*) te istovremeno i na manjak vjerovanja u osobne kompetencije (*Self Assessment*). Stoga je utjecaj navedenih varijabli evaluiran s “*S+*” i “*W+*”, respektivno. Sljedeći uzorak ponašanja (*BP3*) sadržava logičke odluke koje ovise o stanjima senzora u okolini te podrazumijeva korištenje različitih vrsta hvataljki što zahtjeva i određenu razinu vjerovanja u dobru ekipiranost, tj. u vlastite kompetencije. Stoga su utjecaji roditelja na ovaj uzorak ponašanja postavljeni na “*M+*” i “*M+*”, respektivno. Na temelju istog promišljanja definirani su utjecaji roditelja na sljedeća dva uzorka ponašanja (*BP4* i *BP5*) budući da je svaki sljedeći kompleksniji od prethodnog. Sljedeća tablica [Tablica 5-7] prikazuje korigirane vrijednosti utjecaja.

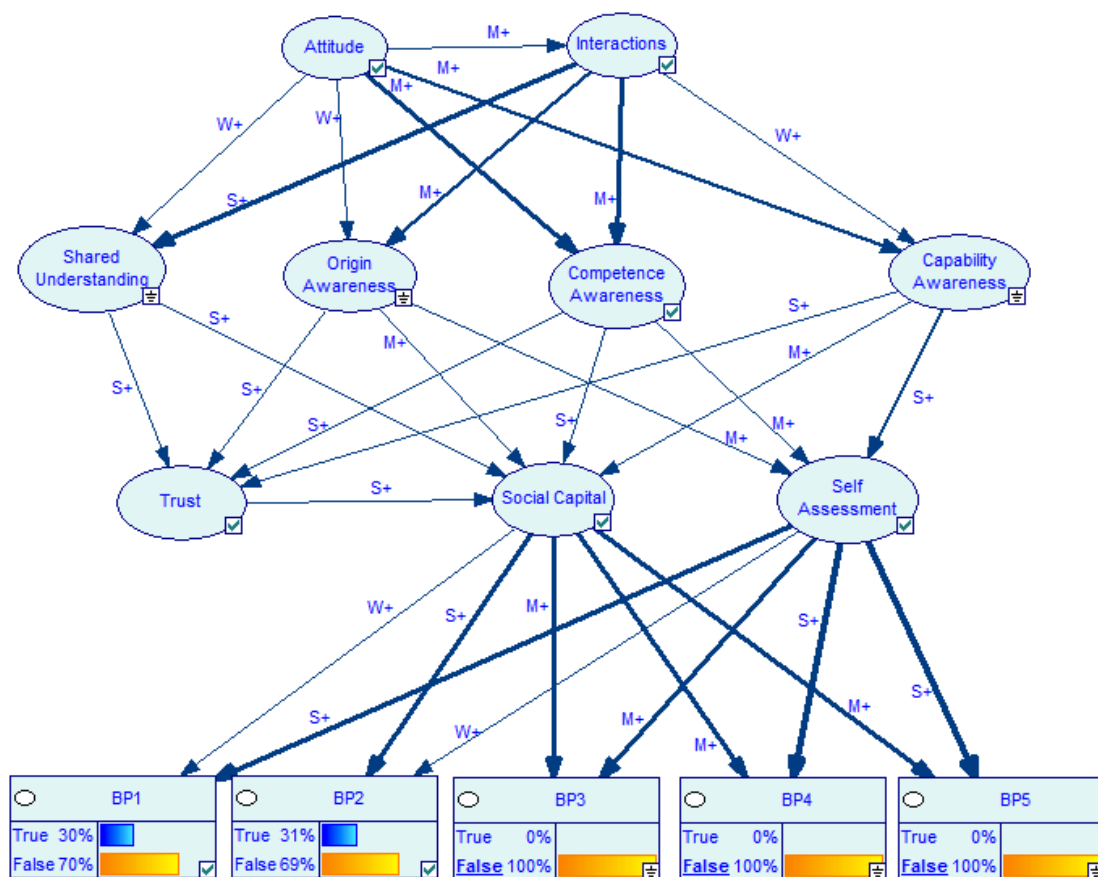
Tablica 5-7. Korigirani postav utjecaja varijabli roditelja na varijable *BP_n*.

Uzorak ponašanja	Snaga utjecaja	
	<i>Social Capital</i>	<i>Self Assessment</i>
<i>BP1</i>	<i>W+</i>	<i>S+</i>
<i>BP2</i>	<i>S+</i>	<i>W+</i>
<i>BP3</i>	<i>M+</i>	<i>M+</i>
<i>BP4</i>	<i>M+</i>	<i>S+</i>
<i>BP5</i>	<i>M+</i>	<i>S+</i>

Budući da je došlo do promijene utjecaja varijabli roditelja na uzorke ponašanja, potrebno je izvršiti ponovni proračun vrijednosti uvjetnih varijabli za te čvorove (*Prilog D*). U skladu s odzivima mreže, odabrani uzorak ponašanja je onaj koji ima najveću vjerojatnost.

Sljedeća slika [Slika 5-32] prikazuje stanje mreže nakon korekcija težinskih faktora i bez unesenog dokaza o kompetentnosti robota koji šalje upit. Kao što je moguće vidjeti, mreža sada nudi *BP2* kao rješenje što znači da je sklonija propustiti nosač proizvoda (*PC*) do sljedećeg radnog mjesta ako nije “sigurna” u dostatnu ekipiranost robota. U slučaju da mreža unutar upita primi dokaz da je robot kompetentan [Slika 5-33], ponuđeno rješenje će tada biti *BP1* što je u skladu s prethodnim razmišljanjima. Zadnji slučaj koji predstavlja odziv mreže kod nekompetentno ocijenjenog robota zajedno s pripadajućim rješenjem (*BP2*) prikazan je

na [Slika 5-34]. Time je ispitivanje mreže za ovu kombinaciju uzoraka ponašanja i dokaza o kompetencijama robota završen.



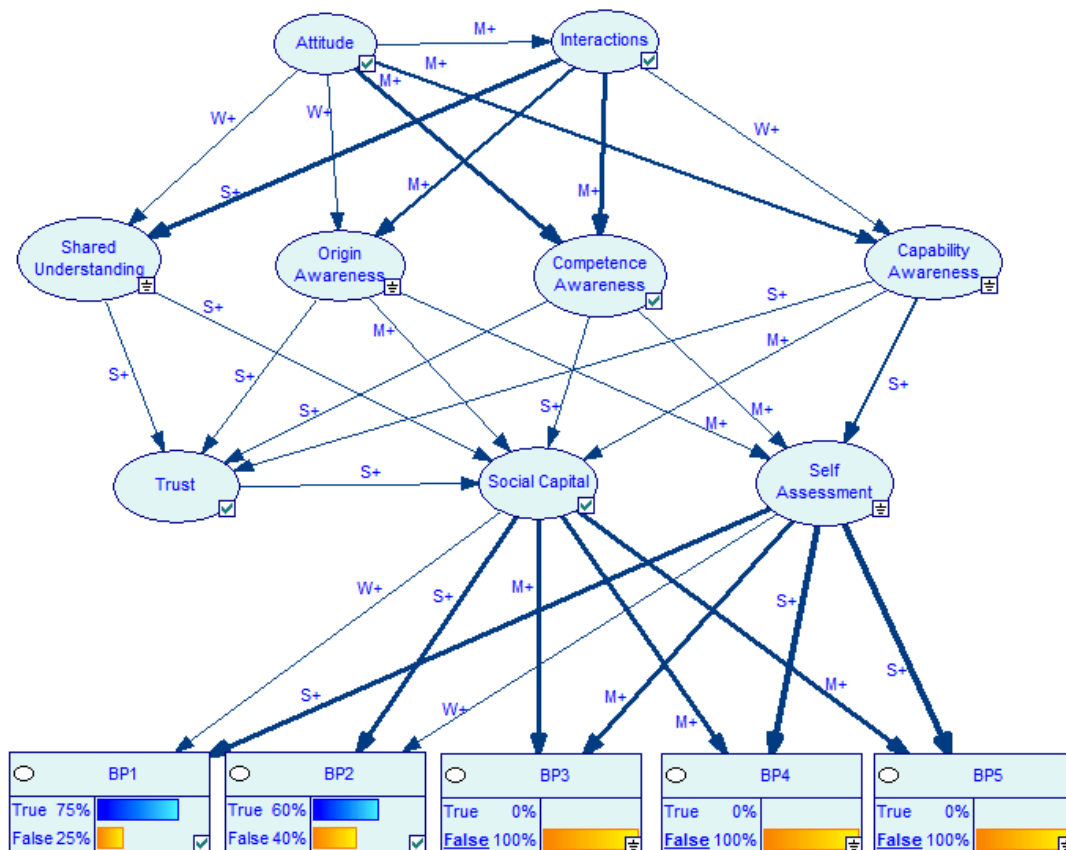
Slika 5-32. Razvoj – prvi scenarij, korigirano, odluka za BP1 ili BP2, 0.

Slika [Slika 5-35] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

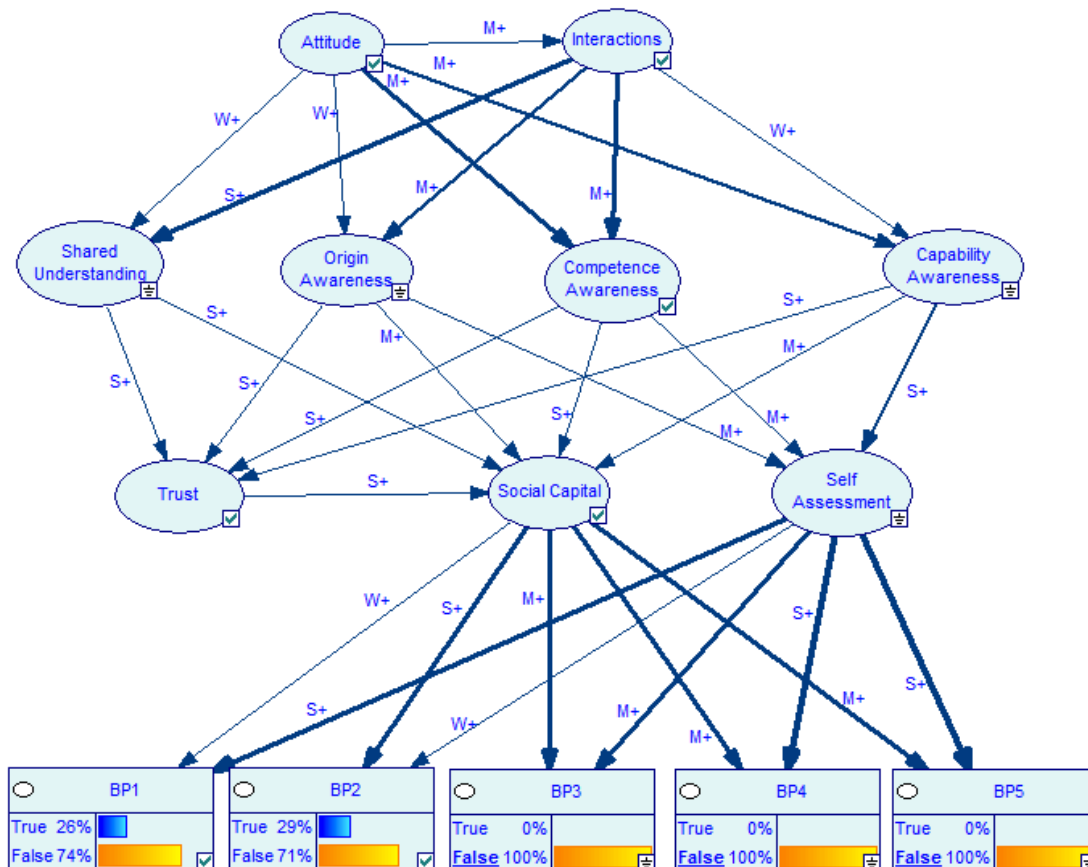
- $Query = [[1, 1, 1, 0, 0], competent]$,

koji sugerira mreži uzorke *BP1*, *BP2* i *BP3* kao rješenja na trenutno stanje u okolini pod pretpostavkom da je robot koji postavlja upit zadovoljavajuće ekipiran.

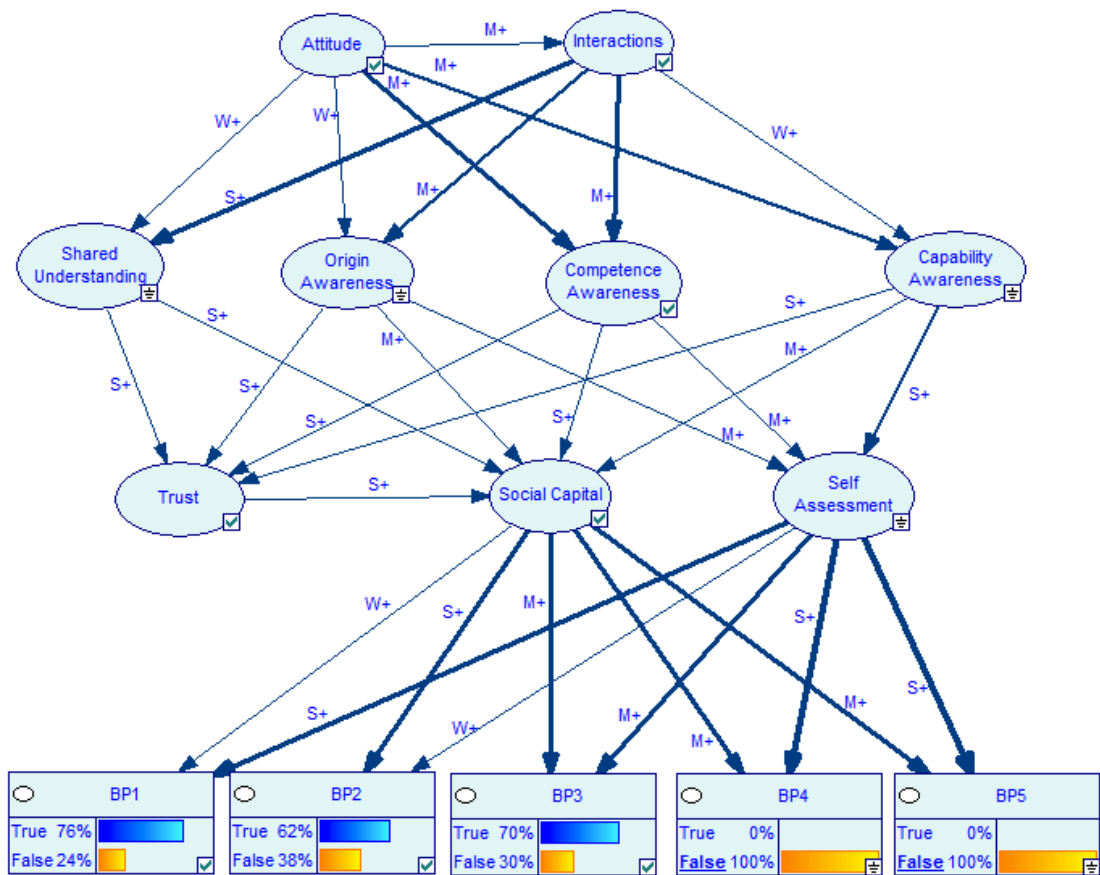
Razvijena Bayesova mreža odražava vjerovanje da je *BNI* najbolji odabir, čime je prevladalo vjerovanje da je robotu najbolje pričekati umjesto da odradi *BP3*. U ovome primjeru se jako lijepo vidi kako su dokazi koji iskazuju nepovjerenje u grupu utjecali na vrijednost socijalnog kapitala. Varijanta u kojoj nekompetentni robot šalje upit, sugerira *BP2* kao rješenje što označava propuštanje nosača proizvoda do sljedećeg radnog mjesta [Slika 5-36].



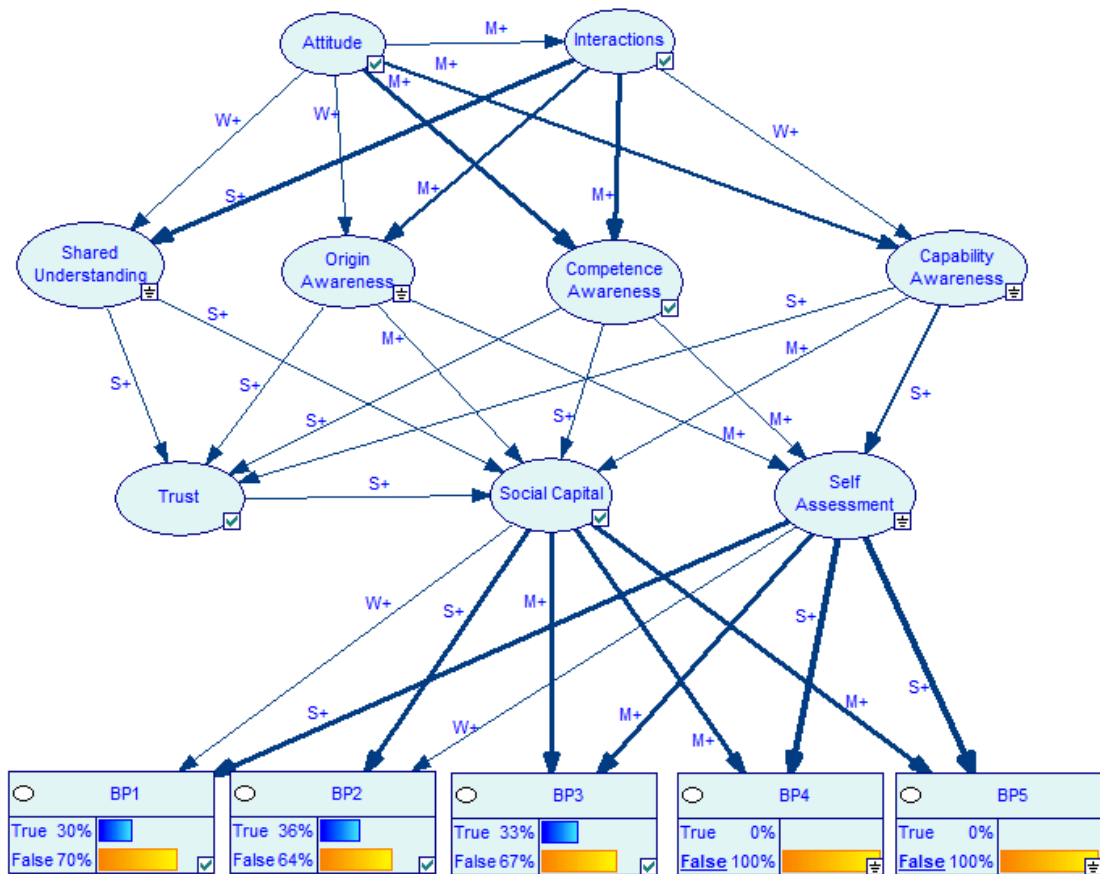
Slika 5-33. Razvoj – prvi scenarij, korigirano, odluka za BP1 ili BP2, competent.



Slika 5-34. Razvoj – prvi scenarij, korigirano, odluka za BP1 ili BP2, incompetent.



Slika 5-35. Razvoj – prvi scenarij, odluka za BN1, BP2 ili BP3, competent.



Slika 5-36. Razvoj – prvi scenarij, odluka za BN1, BP2 ili BP3, incompetent.

Navedeno rješenje je ispravno budući da robot zbog nedovoljne ekipiranosti ne može izvršiti *BP3*. Također, iz istog razlog robot nema smisla čekati da se nešto promijeni na samom radnom mjestu (odabir *BP1*).

Slika [Slika 5-37] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

- $Query = [[0, 1, 0, 1, 0], 0/imcompetent/competent]$,

koji sugerira mreži uzorke *BP2* i *BP4* kao rješenja na trenutno stanje u okolini. U slučaju prikazanom na slici, kada je robot ocijenjen kao kompetentan, mreža će ponuditi odabir *BP4* što znači da se pouzda u individualnu ocjenu stručnjaka o stanju promatranog robota. U slučaju da je robot ocijenjen kao nekompetentan mreža će sugerirati odabir *BP2*, odnosno ponudit će propuštanje nosača proizvoda (*PC*) do sljedećeg radnog mjesta [Slika 5-38] što je u skladu s uvjerenjima stručnjaka o tome kako bi se sustav trebao ponašati.

Slika [Slika 5-39] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

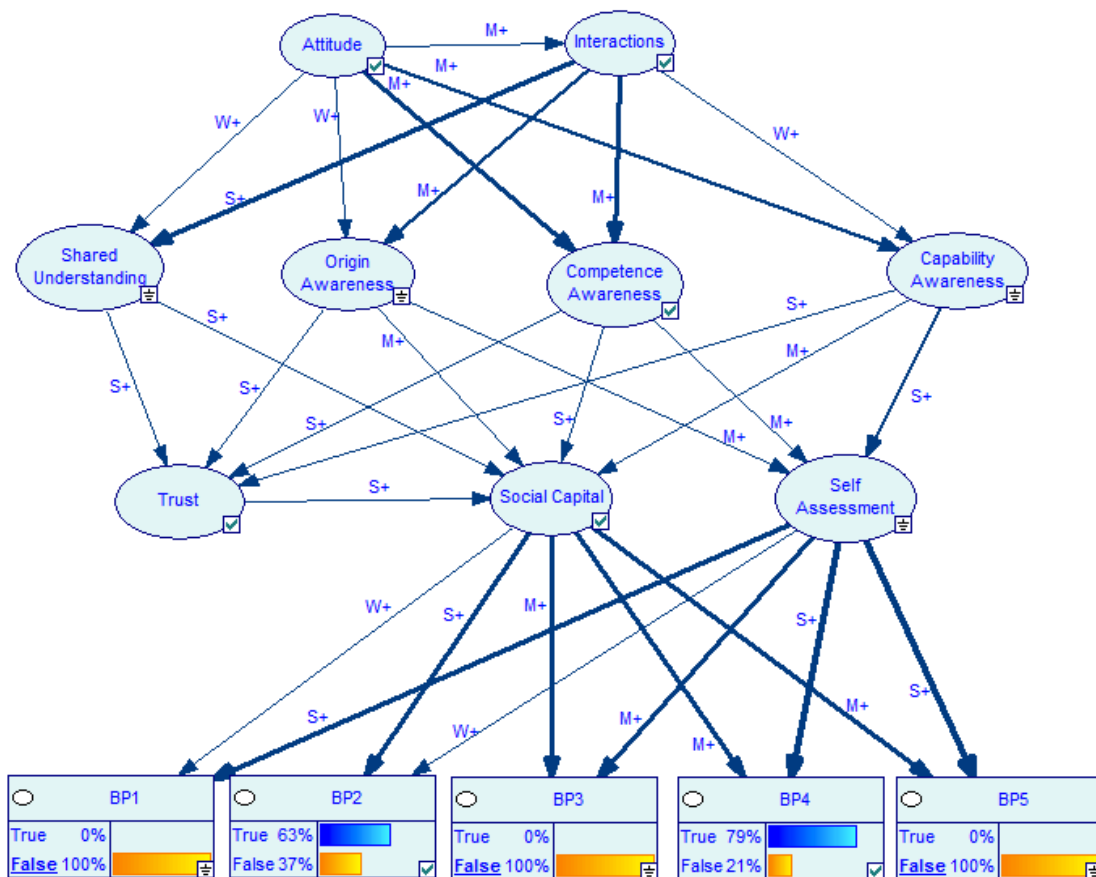
- $Query = [[0, 1, 0, 0, 1], 0/imcompetent/competent]$,

koji sugerira mreži uzorke *BP2* i *BP5* kao rješenja na trenutno stanje u okolini. U slučaju prikazanom na slici kada je robot ocijenjen kao kompetentan, mreža će ponuditi odabir *BP5*, što je u skladu s ranije navedenom analizom u kojoj se mreža “oslanja” na individualnu ocjenu stručnjaka. U slučaju da je robot ocijenjen kao nekompetentan, mreža će sugerirati odabir *BP2* (propuštanje) [Slika 5-38].

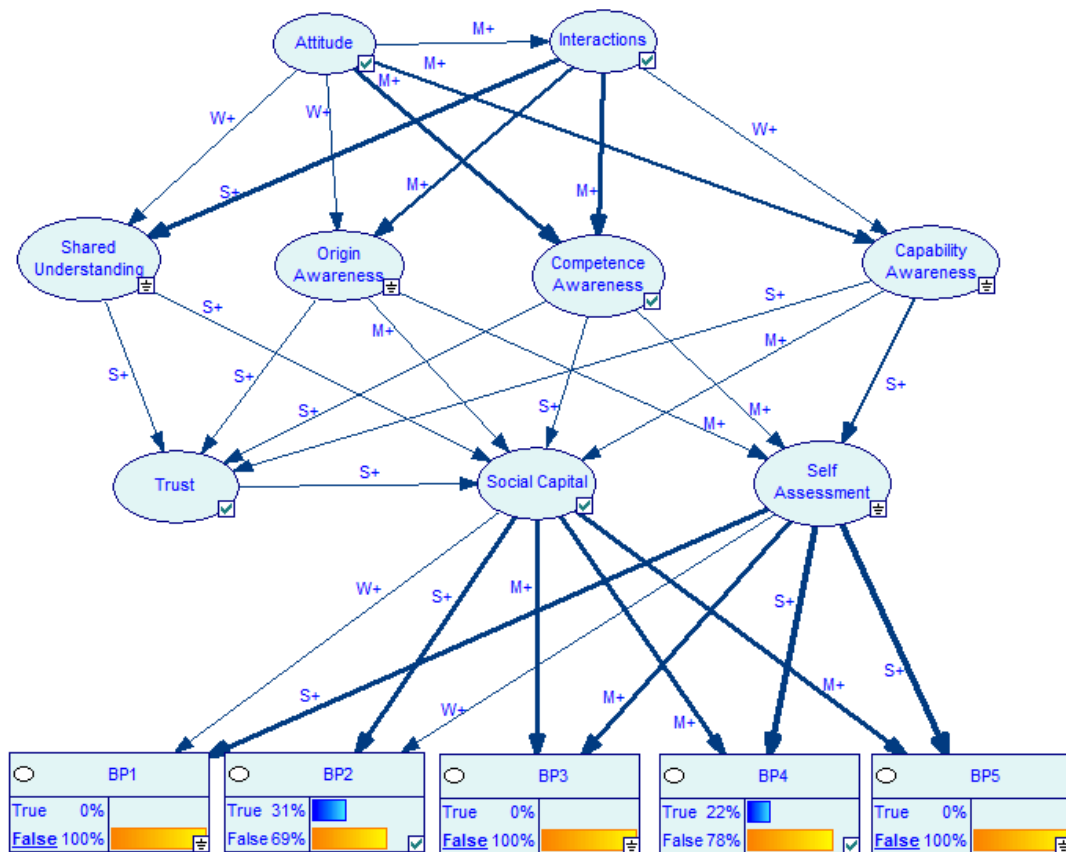
Slika [Slika 5-40] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

- $Query = [[0, 1, 1, 0, 0], 0/imcompetent/competent]$,

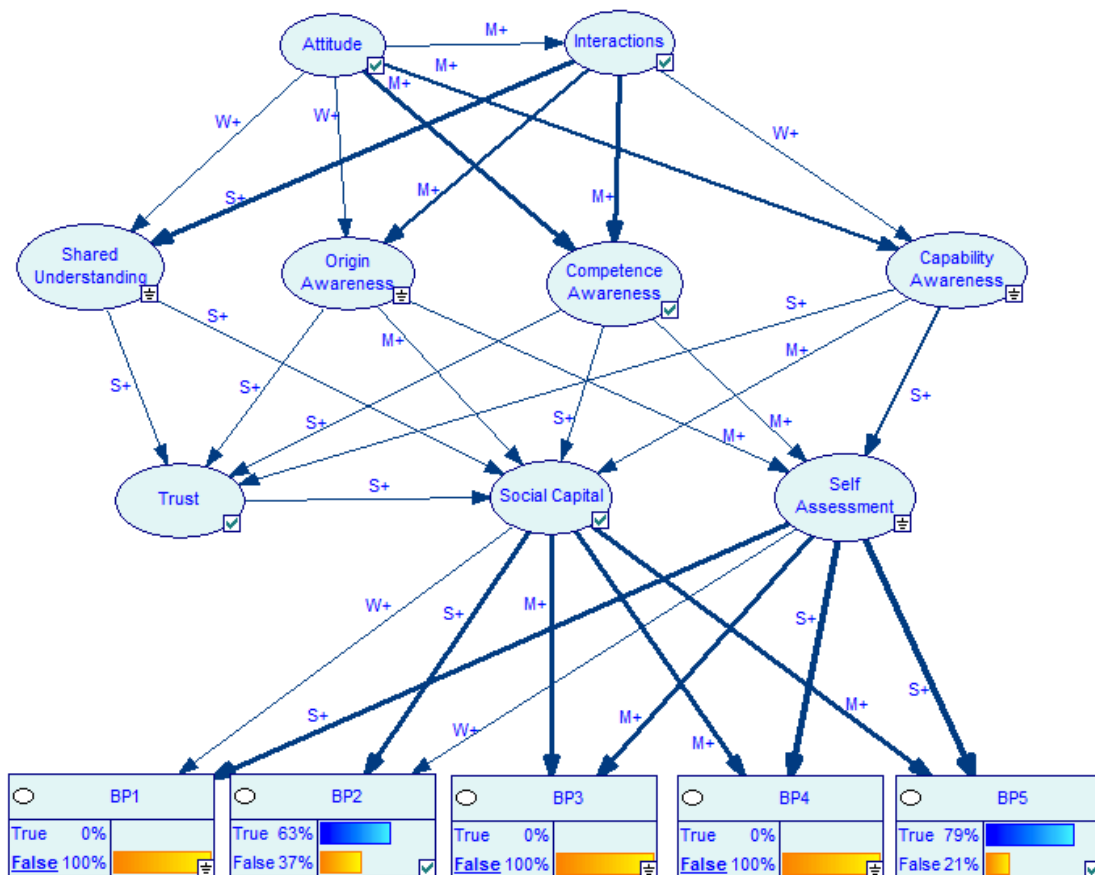
koji sugerira mreži uzorke *BP2* i *BP3* kao rješenja na trenutno stanje u okolini. U slučaju kompetentnog robota, Bayesova mreža sugerira *BP3* kao rješenje budući da je kompleksniji te zahtjeva robota koji je prikladno ekipiran. Ako je robot ocijenjen kao nekompetentan, kao što je vidljivo iz slike [Slika 5-40], mreža će odabrati *BP2* sugeriravši propuštanje nosača proizvoda (*PC*) sljedećem robotu u grupi. Ova kombinacija rješenja predstavlja zadnju moguću koju ontološka jezgre može dovesti na ulaz u Bayesovoj mreži. Time je proces razvoja i analize mreže u sklopu prvog scenarija završen. U ovoj fazi razvoja te u sklopu prvog scenarija, korigirani težinski faktori su omogućili Bayesovoj mreži da vraća odzive koji su u skladu s uvjerenjima ljudskog stručnjaka. Proces validacije i verifikacije mreže, koji u sebi sadrži fazu evaluacije, odnosno ispitivanja bit će nastavljen u šestoj cjelini koristeći preostala dva scenarija.



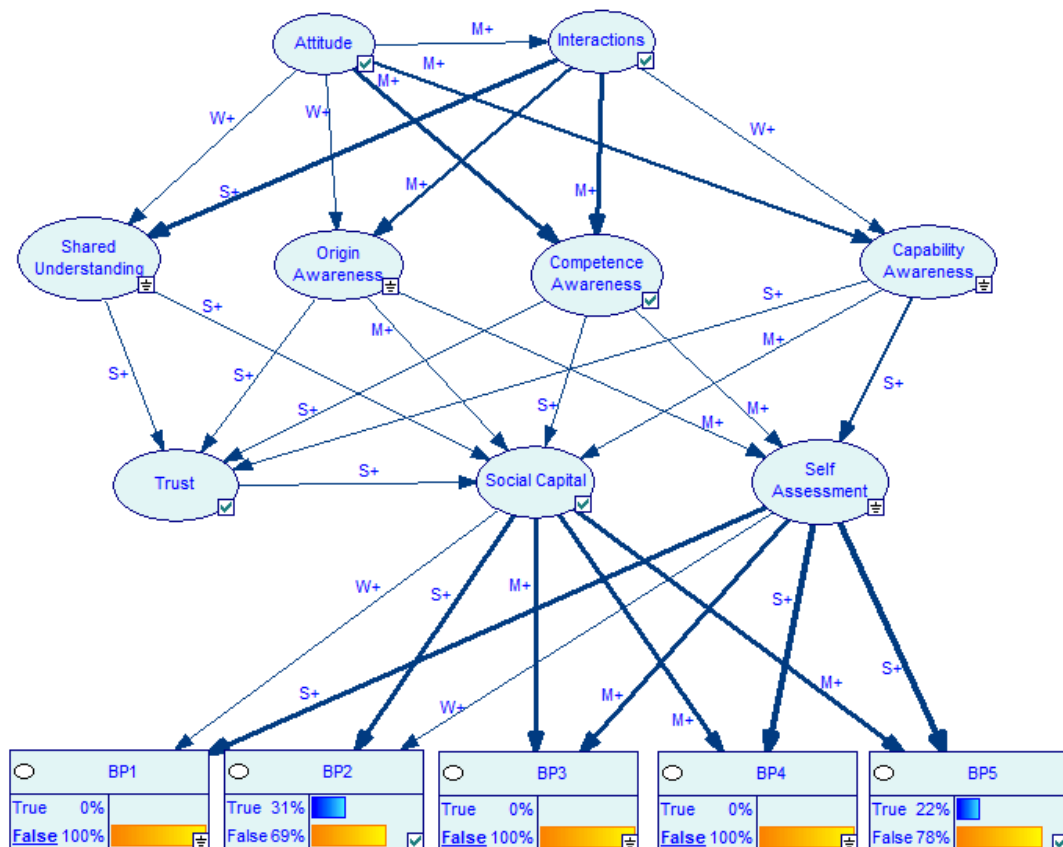
Slika 5-37. Razvoj – prvi scenarij, odluka za BP2 ili BP4, competent.



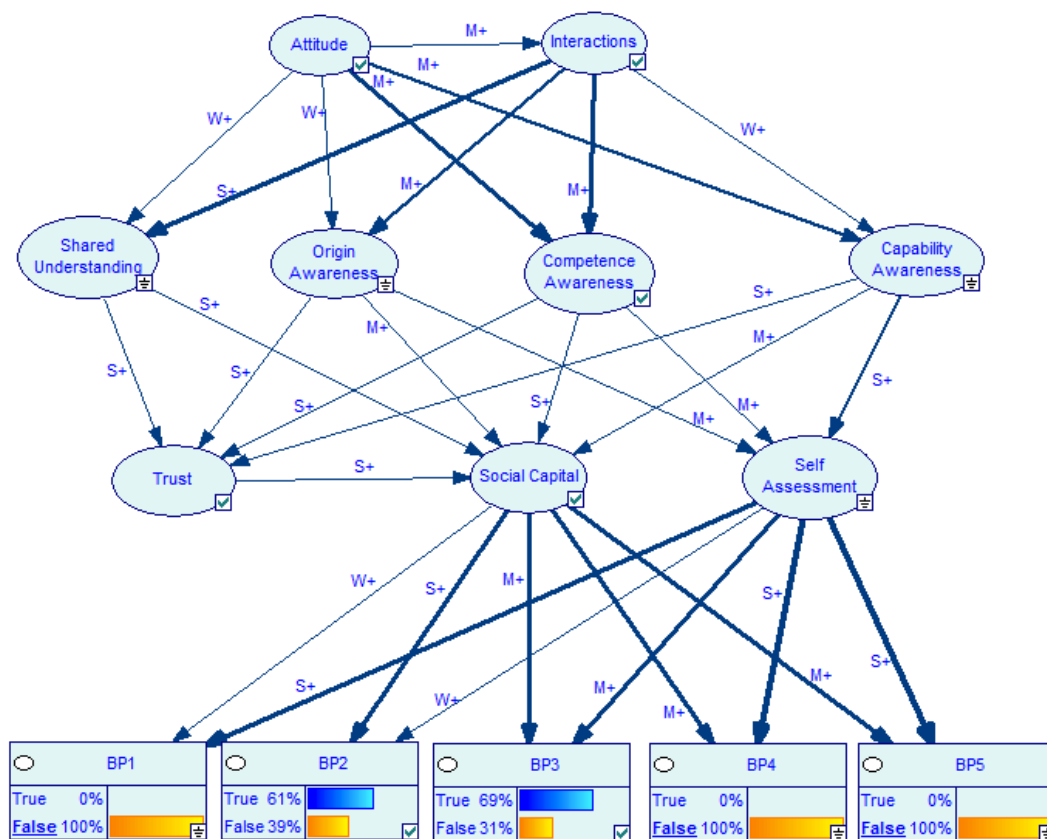
Slika 5-38. Razvoj – prvi scenarij, odluka za BP2 ili BP4, incompetent.



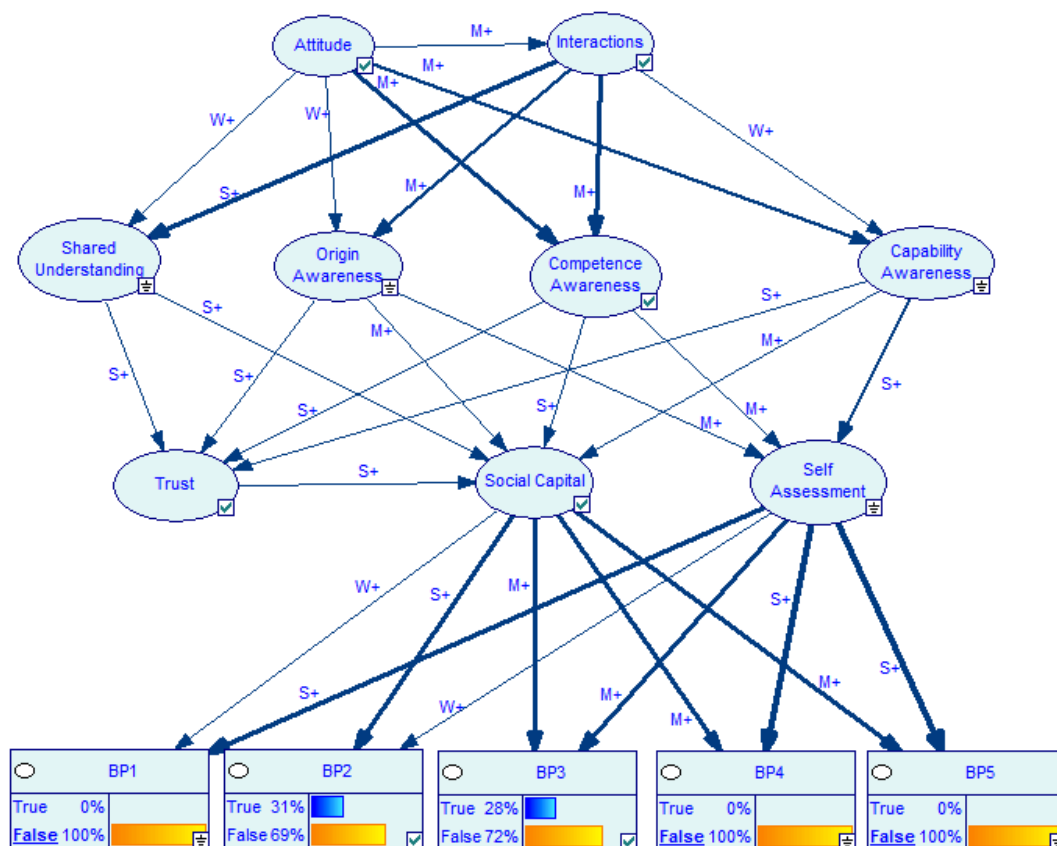
Slika 5-39. Razvoj – prvi scenarij, odluka za BP2 ili BP5, competent.



Slika 5-40. Razvoj – prvi scenarij, odluka za BP2 ili BP5, incompetent.



Slika 5-41. Razvoj – prvi scenarij, odluka za BP2 ili BP3, competent.



Slika 5-42. Razvoj – prvi scenarij, odluka za BP2 ili BP3, incompetent.

6. VALIDACIJA I VERIFIKACIJA PREDLOŽENE METODOLOGIJE

6.1. Drugi scenarij

Koristeći ulazne informacija prikupljene od strane stručnjaka koji je dao svoje subjektivne ocjene trenutnog stanja grupe robota za preostala dva scenarija, provedeno je ispitivanje definiranog postava mreže čime je ocijenjena dobrota rješenja.

U sklopu opisa drugog scenarija moguće je iščitati sljedeće vrijednosti varijabli mreže:

- *Attitude = positive; Shared Understanding = high; Origin Awareness = present; Capability Awareness = present; Self Assessment = 0/competent/incompetent.*

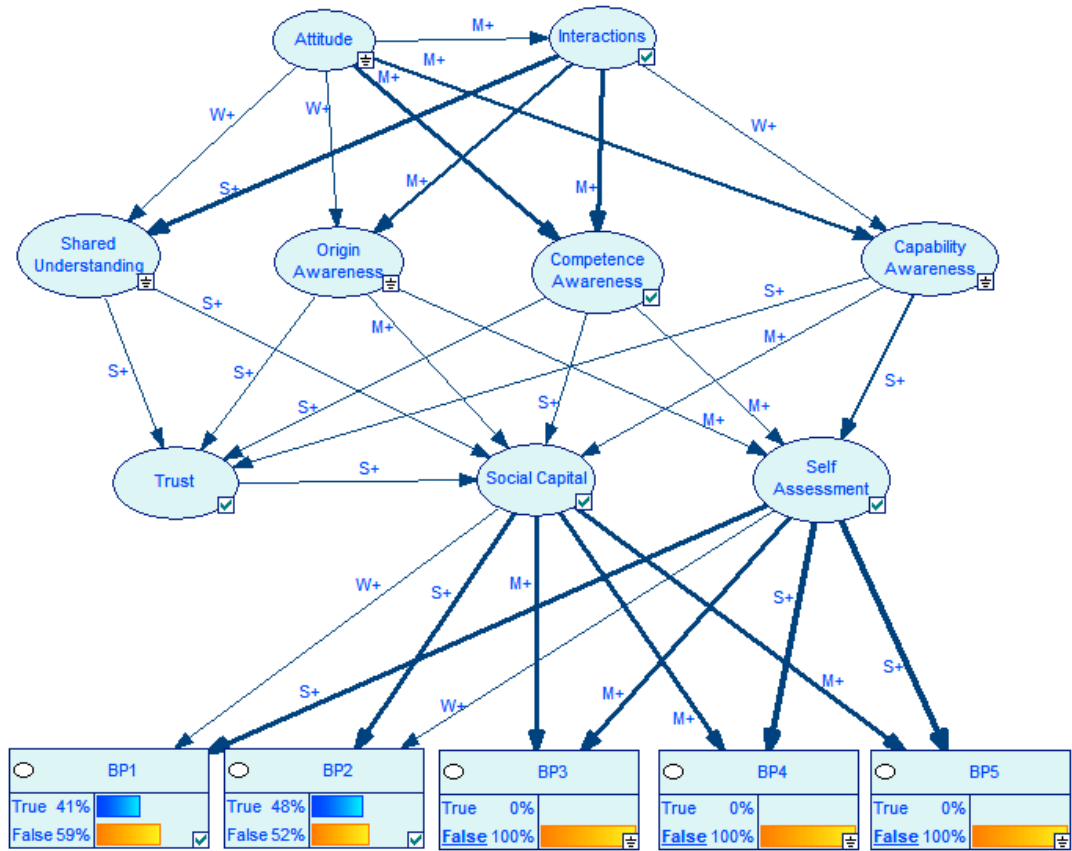
Slika [Slika 6-1] sadrži odzive mreže ako je na ulaz doveden sljedeći upit:

- *Query = [[1, 1, 0, 0, 0], 0/imcompetent/competent],*

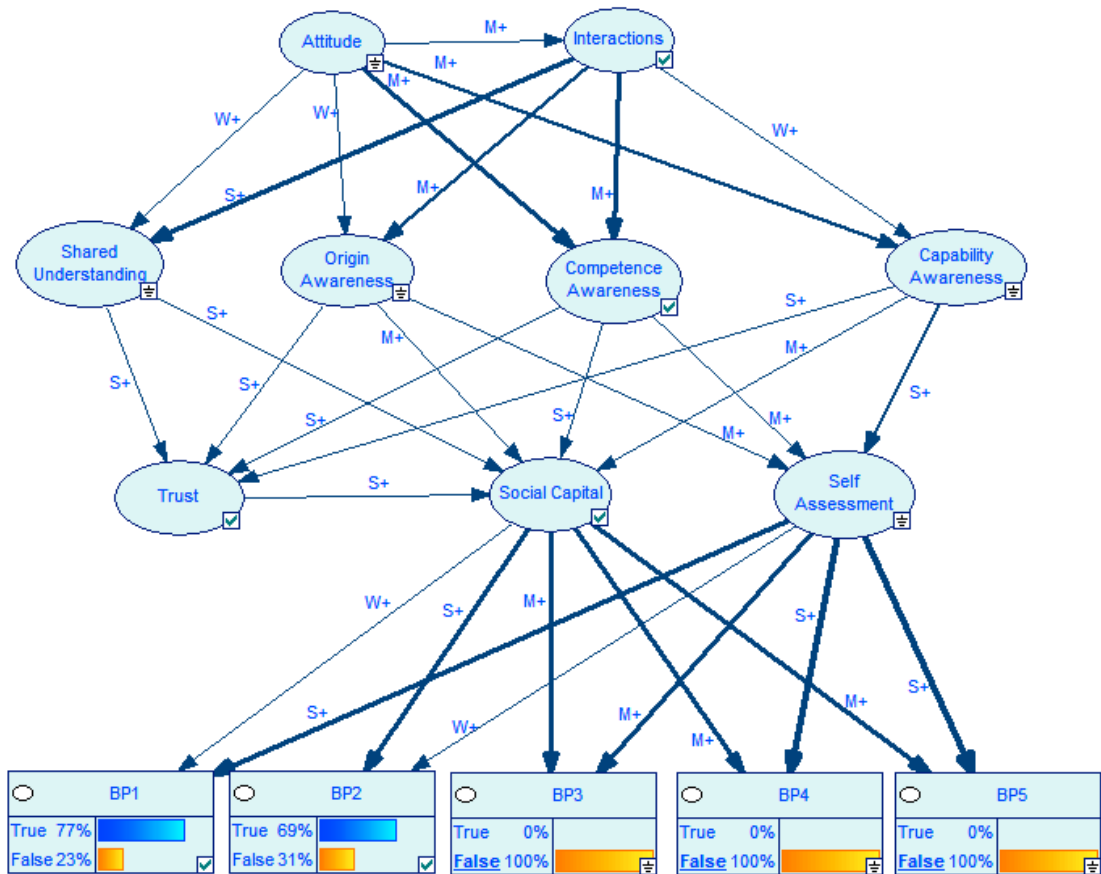
Iako nije bilo potrebno raditi analizu u slučaju da je robot ocijenjen kao nekompetentan budući da su prema drugom scenariju svi roboti proglašeni dostatno ekipiranima, radi cjelovitosti rada provedena je i ta analiza. Kao što je moguće vidjeti iz dostupnih podataka te odziva mreže [Slika 6-1], u slučaju da nije omogućen dokaz *Self Assessment* mreža će radije ponuditi rješenje *BP2* koje se “oslanja” na dokaze o mogućoj ekipiranosti ostalih robota u grupi. To je posljedica izrazito pozitivno orijentiranih dokaza vezanih za postojanje socijalnog kapitala koji rezultira vjerom mreže u sposobnosti grupe.

Slika [Slika 6-2], pokazuje odziv mreže u slučaju da je robot ocijenjen kao kompetentan. U njemu je mreža sugerira odabir *BP1* kao rješenja oslanjajući se na dostavljen dokaz o kompetencijama vjerujući da je robot u stanju raditi druge ponuđene uzorke ponašanja koji predstavljaju odgovor na trenutno stanje u okolini.

Slučaj kada je robot nekompetentno ocijenjen od strane stručnjaka prikazan je na [Slika 6-3]. Kao rješenje, mreža je sada odabrala *BP2* što je u skladu s uvjerenjima stručnjaka o prikladnom ponašanju robota unutar grupe.



Slika 6-1. Ispitivanje – drugi scenarij, odluka za BP1 ili BP2, 0.

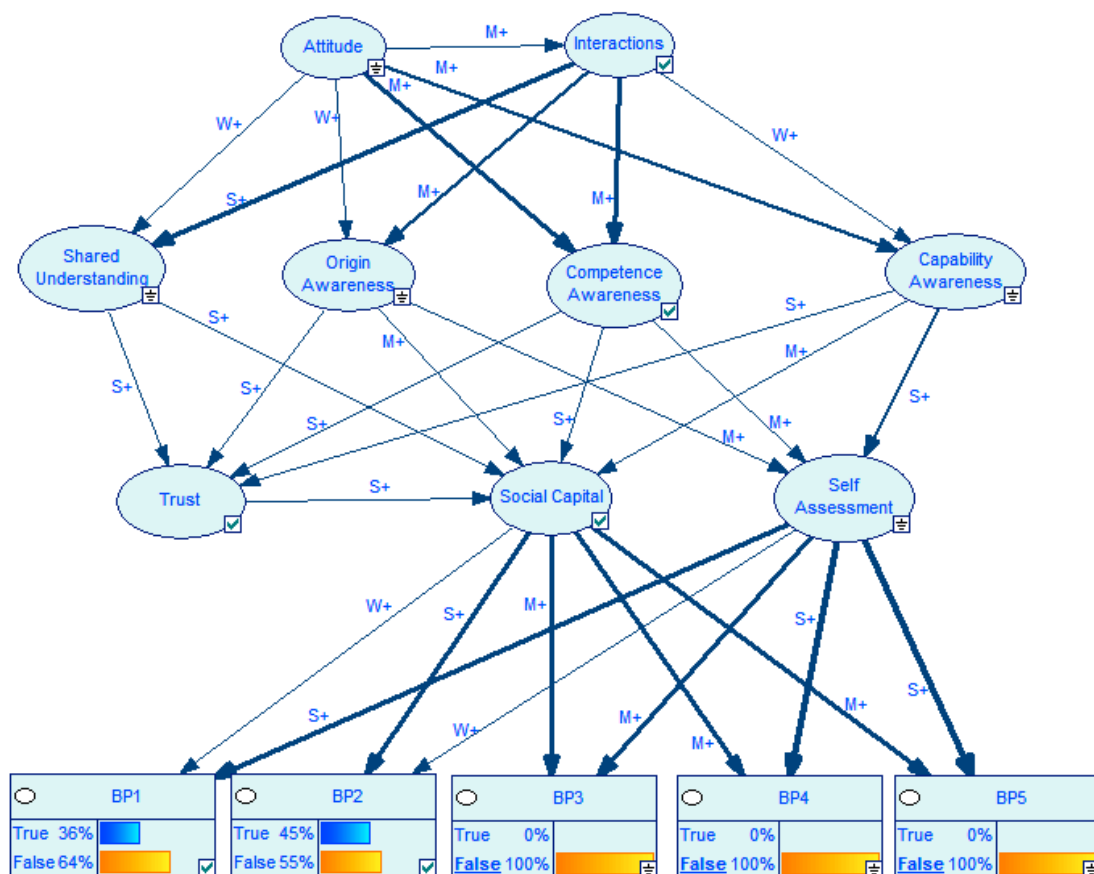


Slika 6-2. Ispitivanje – drugi scenarij, odluka za BP1 ili BP2, competent.

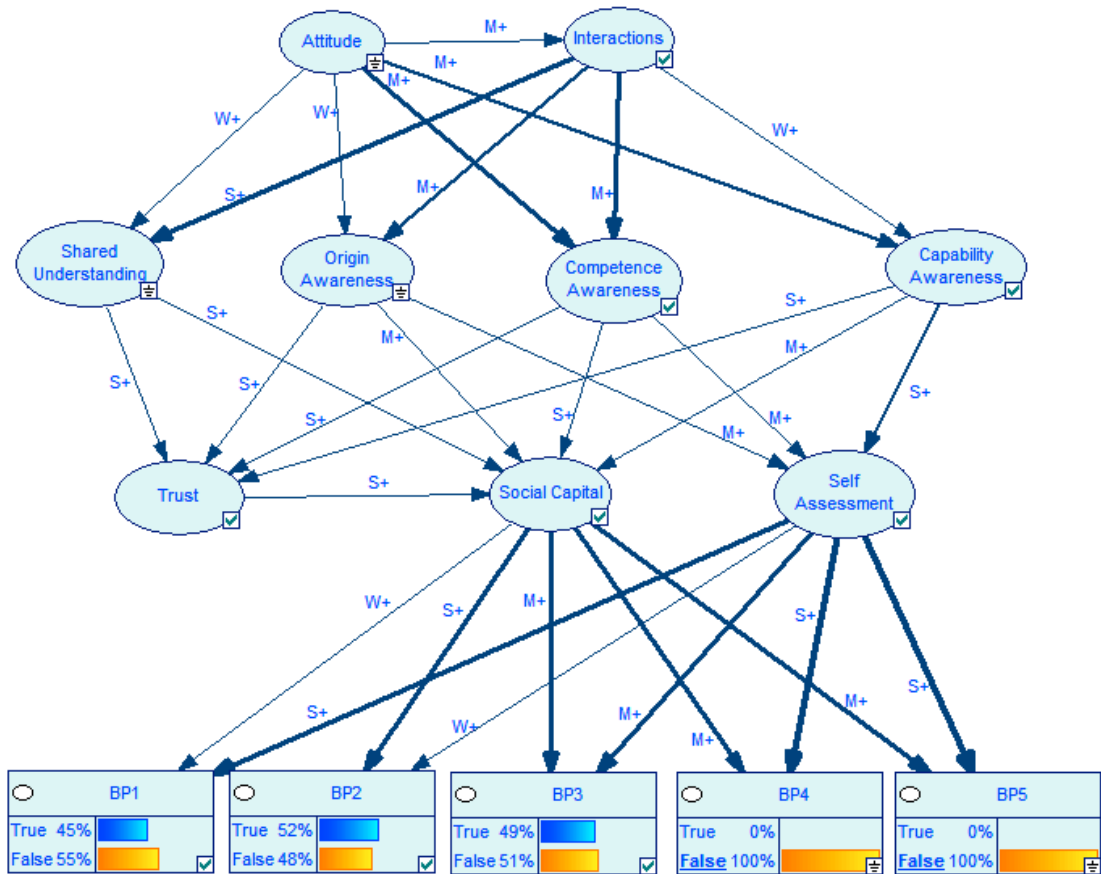
Za slučaj kada mreža na ulaz dobije upit sljedećeg oblika:

- $Query = [[1, 1, 1, 0, 0], 0]$,

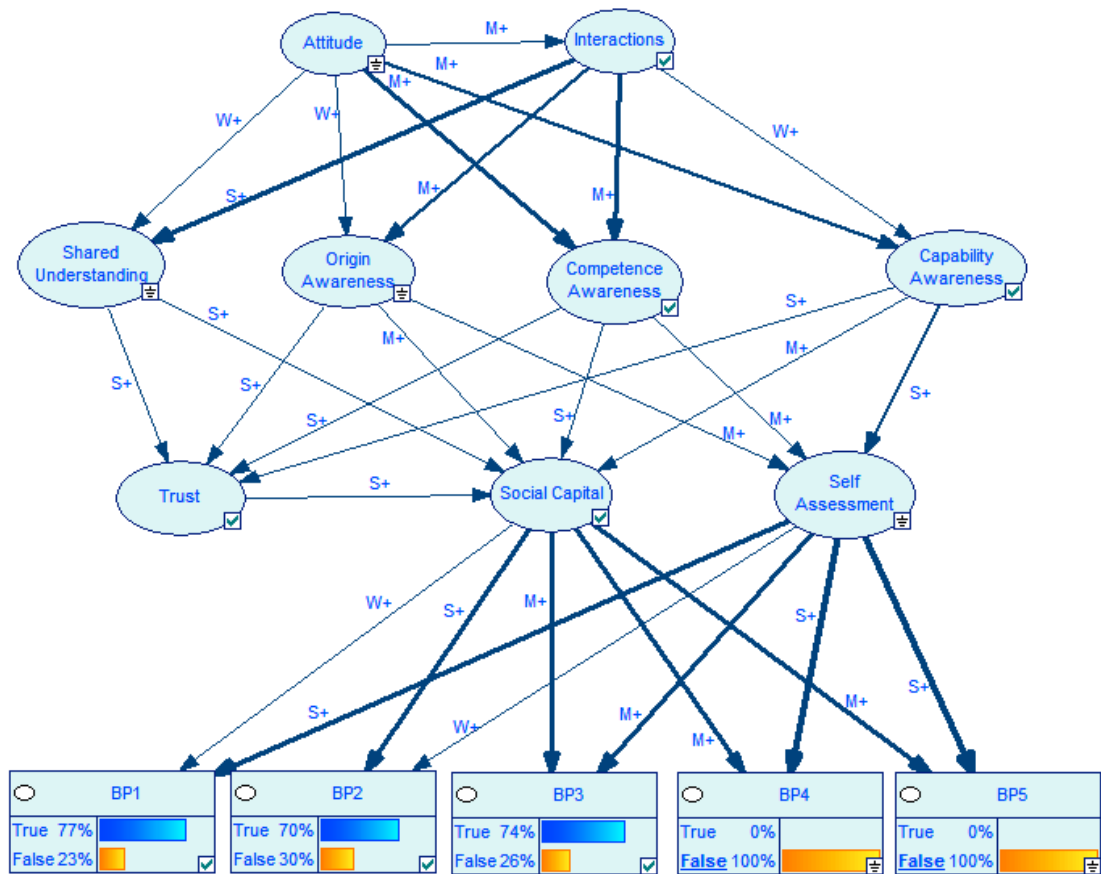
u kojem ontološka jezgra sugerira izvođenje *BP1*, *BP2* ili *BP3*, mreža nudi kao rješenje *BP2* kao odraz vjerovanja u socijalni capital, odnosno u kompetencije ostatka grupe [Slika 6-4]. Ako mreži dostavimo informaciju da je analizirani robot kompetentan proizašlu iz varijable *Self Assessment*, mreža će kao rješenje ponuditi *BP1* [Slika 6-5]. Iako je vidljivo da se mreža oslanja u kompetencije robota, utjecaj varijable *Self Assessment* (*S+*) nadvladava utjecaj varijable *Social Capital* (*M+*) čime je sugerirano robotu da sačeka. Za slučaj u kojem je mreži dostavljen dokaz da je promatrani robot nekompetentan, mreža će prema očekivanjima ponuditi propuštanje nosača proizvoda na sljedeće radno mjesto (*BP2*) [Slika 6-6].



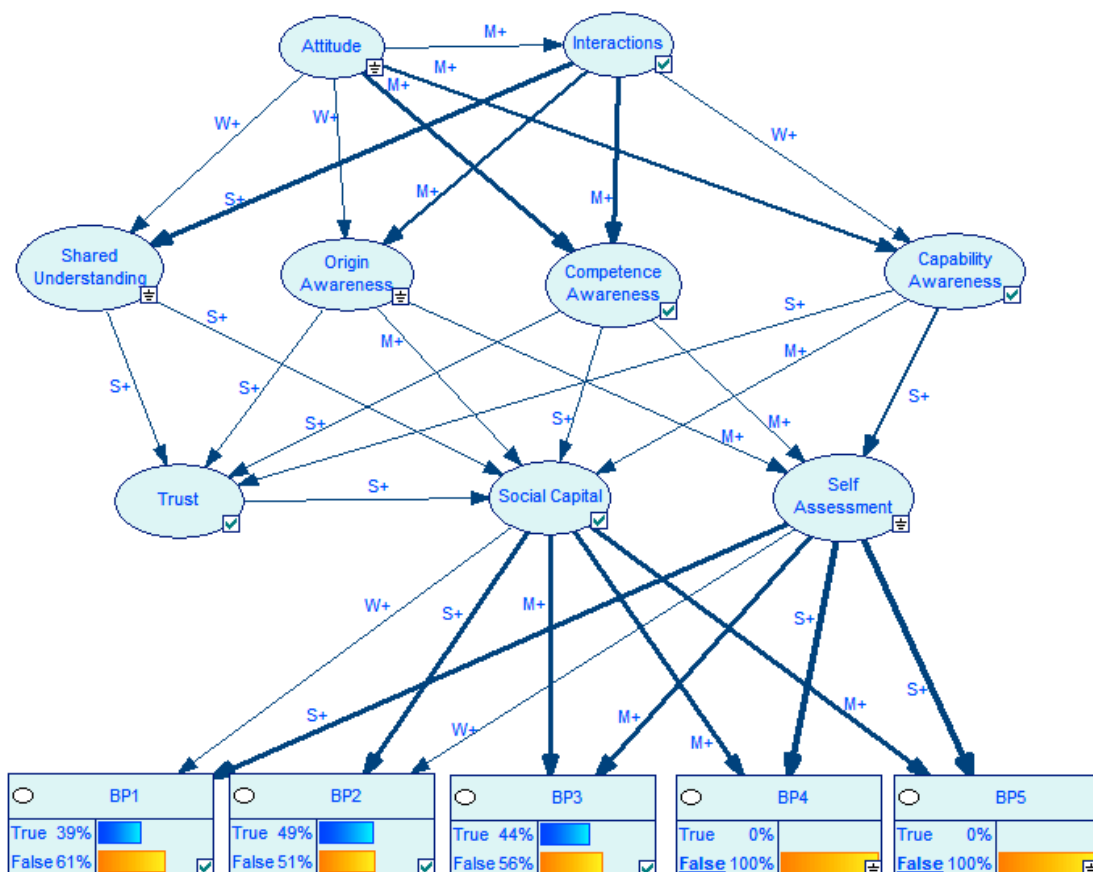
Slika 6-3. Ispitivanje – drugi scenarij, odluka za BP1 ili BP2, incompetent.



Slika 6-4. Ispitivanje – drugi scenarij, odluka za BP1, BP2 ili BP3, 0.



Slika 6-5. Ispitivanje – drugi scenarij, odluka za BP1, BP2 ili BP3, competent.

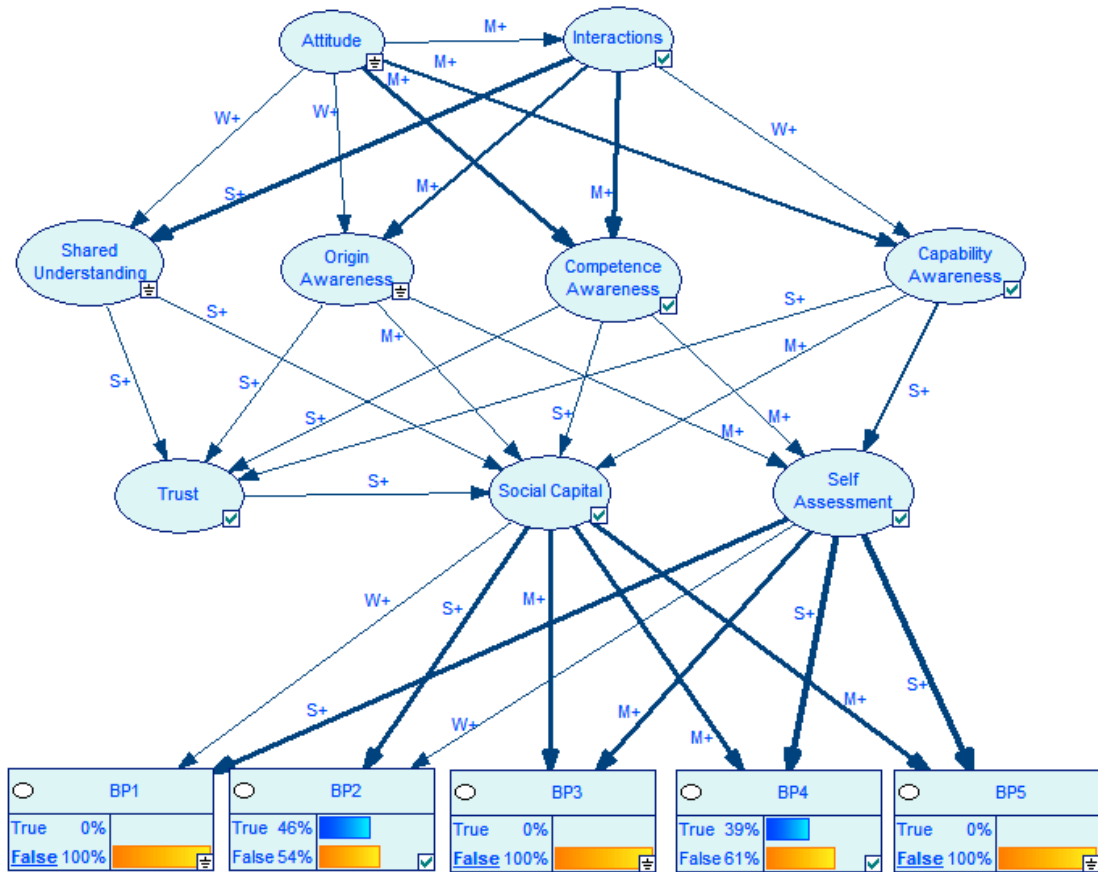


Slika 6-6. Ispitivanje – drugi scenarij, odluka za BP1, BP2 ili BP3, incompetent.

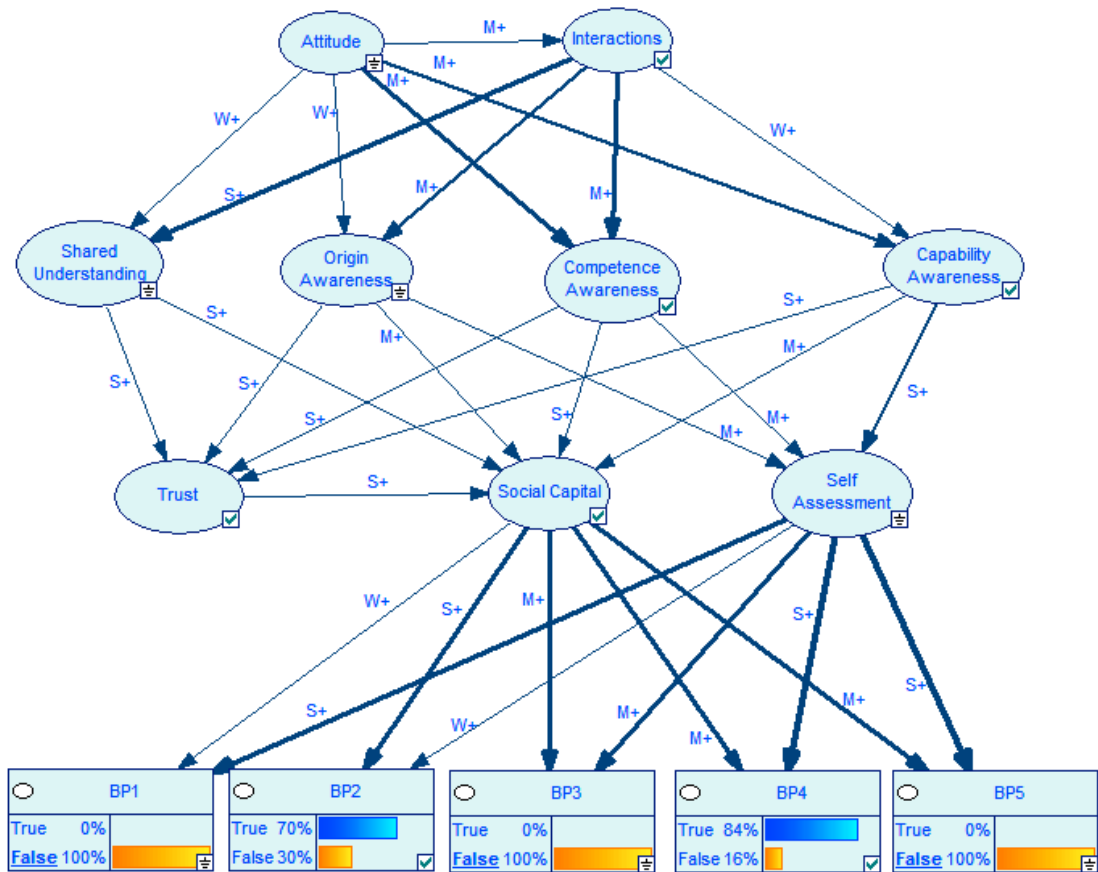
Slučaj u kojem je Bayesova mreža dobila upit:

- $Query = [[0, 1, 0, 1, 0], 0]$,

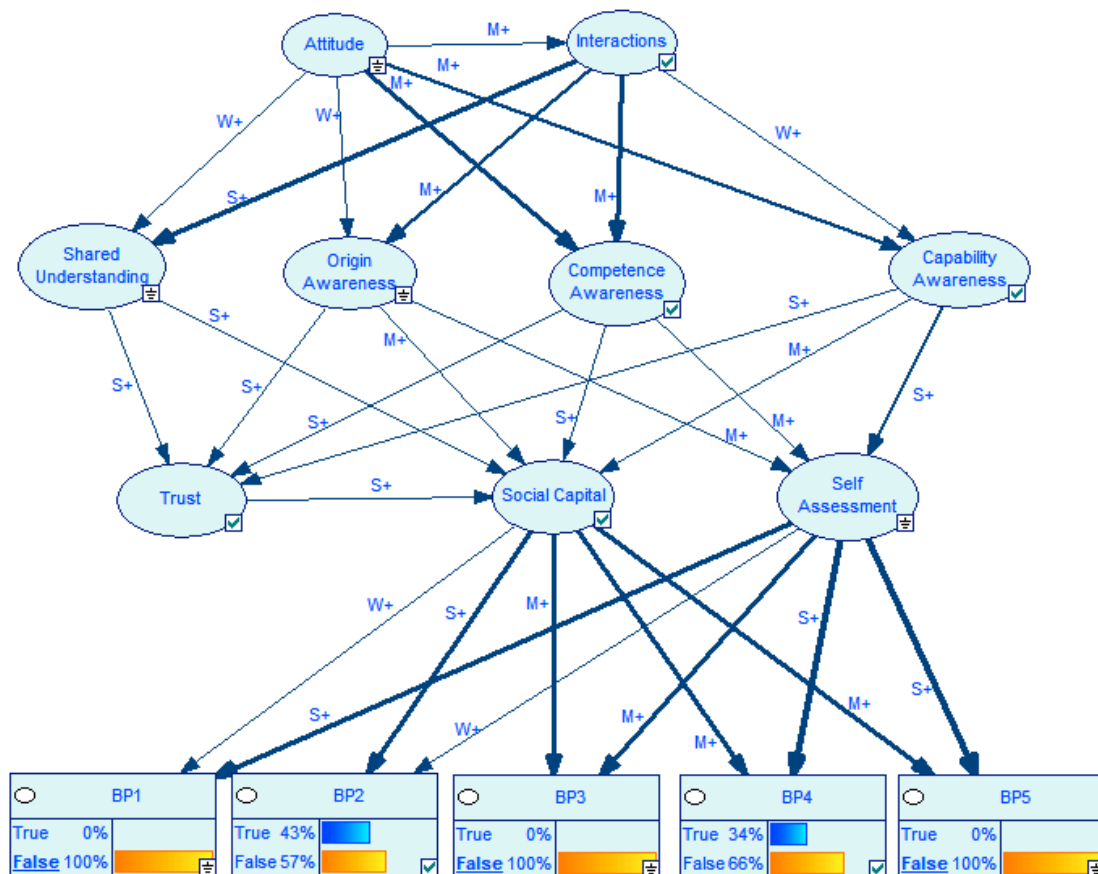
u kojem je sugeriran odabir *BP2* ili *BP4*, mreže vraća odziv koji sugerira *BP2*, odnosno propuštanje nosača proizvoda (*PC*) do sljedećeg radnog mjesta [Slika 6-7]. Zaključivanje mreže je moguće opravdati zahtjevanjem dokaza koji će potvrditi kompetencije robota čime je spriječena mogućnost da je analizirani robot nekompetentan. U slučaju da robot pruži dokaz o svojoj kompetenciji, mreža će kao rješenje ponuditi *BP4* [Slika 6-8]. Zadnji mogućnost, u kojoj mreža sugerira odabir *BP2* kao odgovor na dokaz da je promatrani robot nekompetentan, prikazana je na [Slika 6-9]. Odgovor mreže je u skladu s očekivanjima stručnjaka budući da predstavlja propuštanje nosača proizvoda do sljedećeg, potencijalno kompetentnijeg robota u grupi.



Slika 6-7. Ispitivanje – drugi scenarij, odluka za BP2 ili BP4, 0.



Slika 6-8. Ispitivanje – drugi scenarij, odluka za BP2 ili BP4, competent.

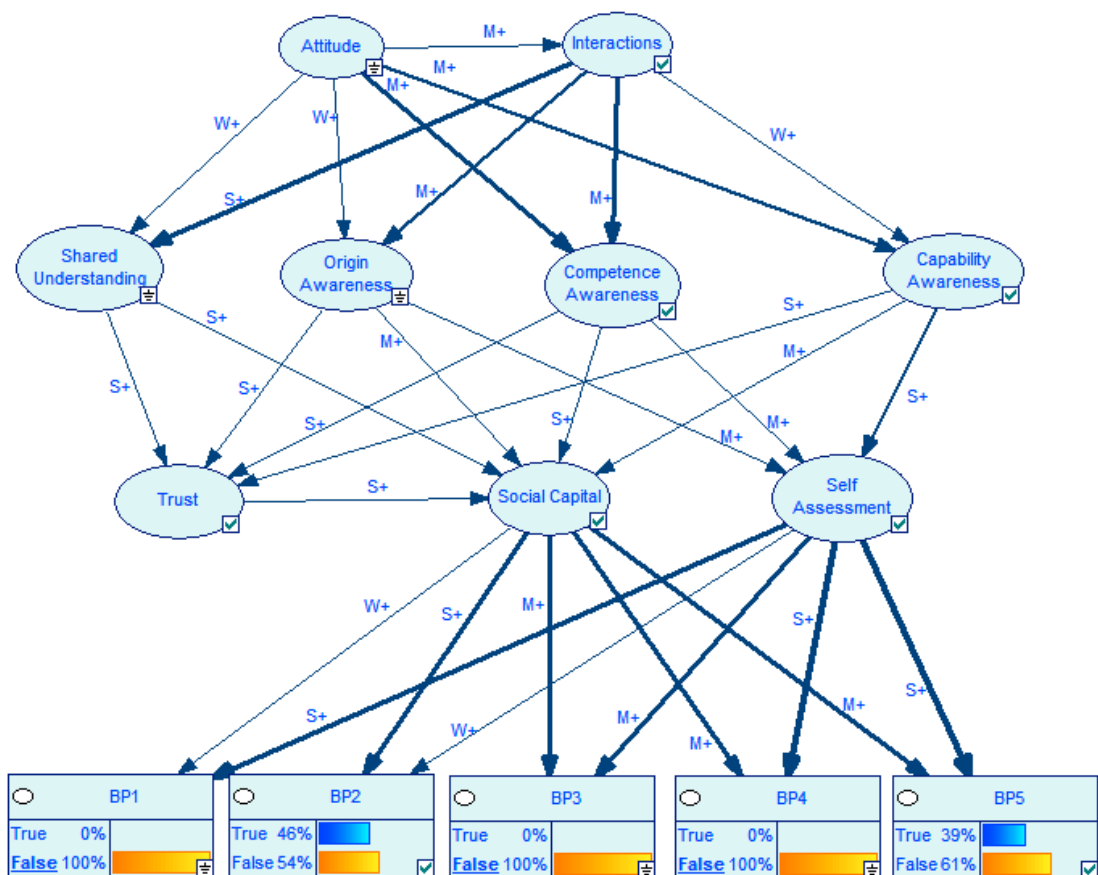


Slika 6-9. Ispitivanje – drugi scenarij, odluka za BP2 ili BP4, incompetent.

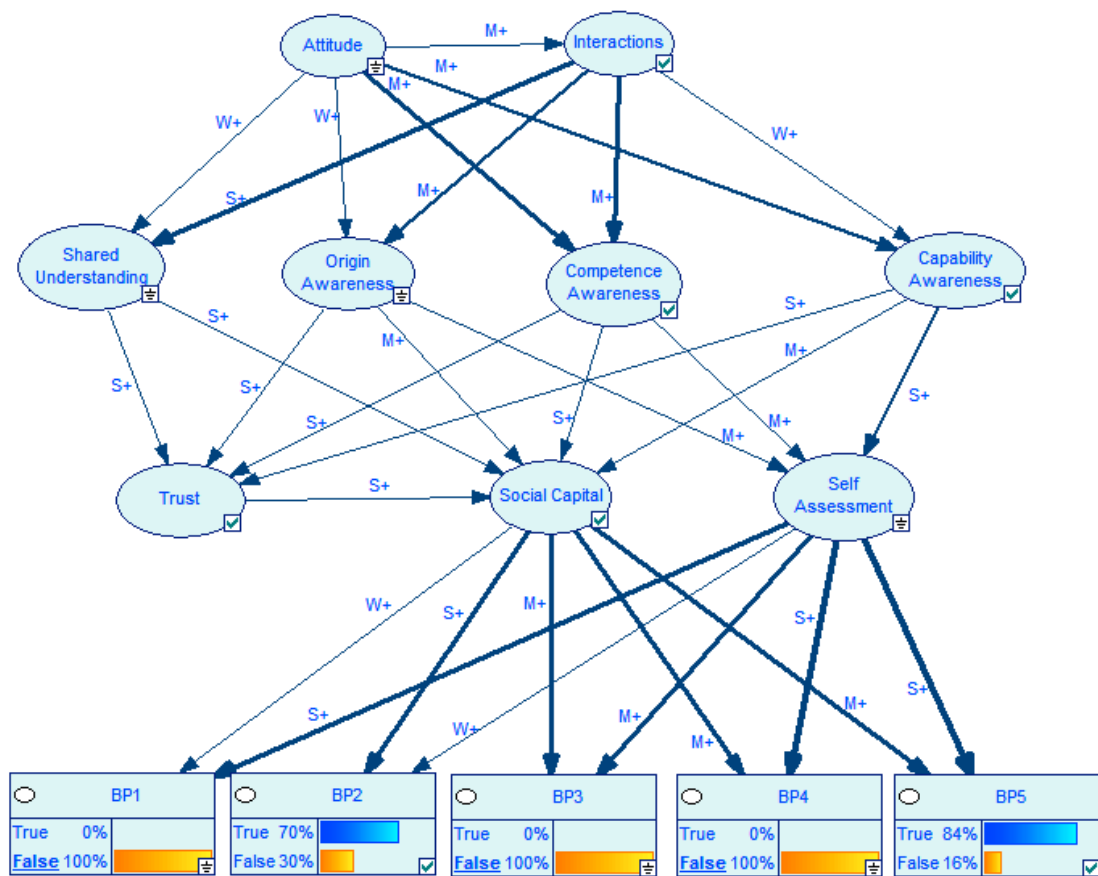
Za slučaj u kojem je mreža dobila upit oblika:

- $Query = [[0, 1, 0, 0, 1], 0]$,

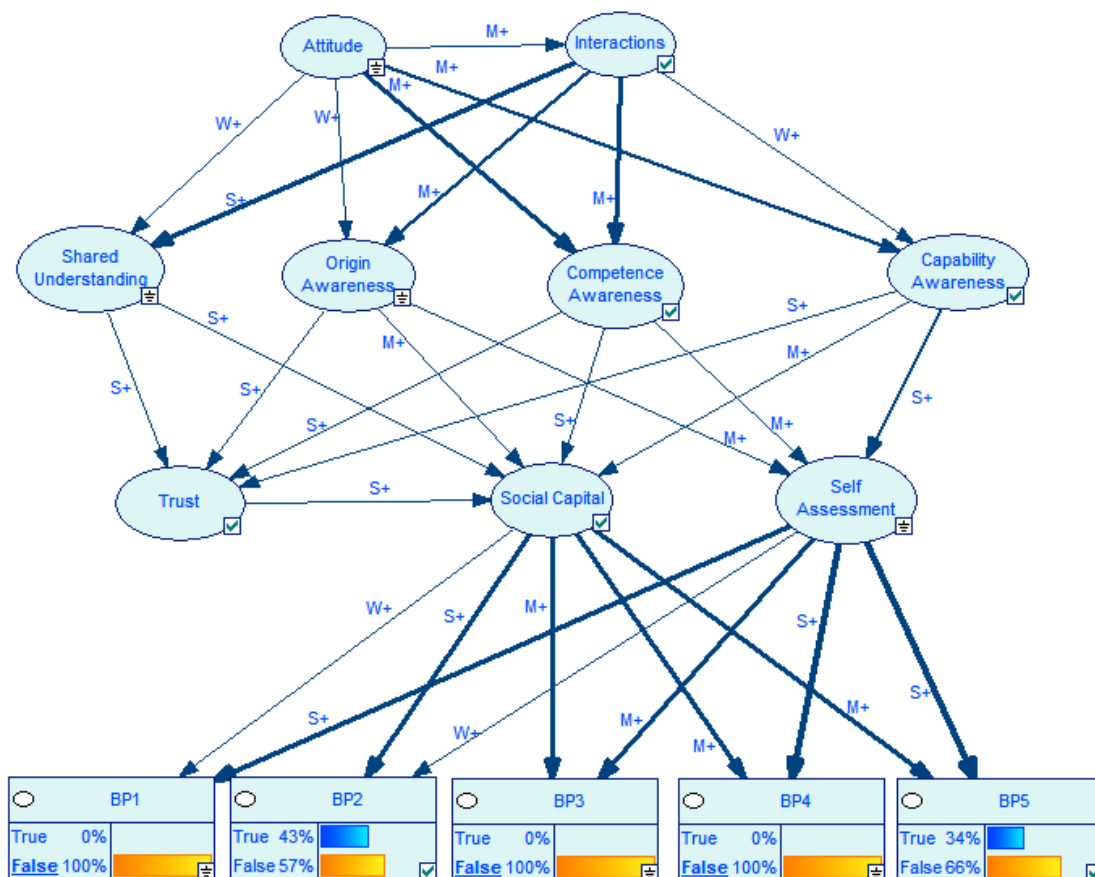
u kojem je sugeriran odabir BP2 ili BP5, mreža vraća odziv koji sugerira BP2, odnosno propuštanje nosača proizvoda (PC) do sljedećeg radnog mjesta [Slika 6-10]. Navedena rješenja su vrlo slična prethodnom slučaju ($Query = [[0, 1, 0, 1, 0], 0]$) što je u skladu s očekivanjima budući da se BP4 i BP5 razlikuju jedino po stupnju kompleksnosti, dok su po funkcijama, alatima i sensorima koje sadržavaju vrlo slični. Kao i u prethodnom slučaju, u slučaju da nije dostavljen dokaz o kompetencijama robota, mreža će se pouzdati u kompetencije grupe. U slučaju da robot pruži dokaz o svojoj kompetenciji, mreža će kao rješenje ponuditi BP5 [Slika 6-11]. Zadnji slučaj, u kojem mreža sugerira odabir BP2 kao odgovor na dokaz da je promatrani robot nekompetentan, prikazan je na [Slika 6-12]. Odgovor mreže je u skladu s očekivanjima stručnjaka budući da predstavlja propuštanje nosača proizvoda (PC) do sljedećeg, potencijalno kompetentnijeg robota u grupi.



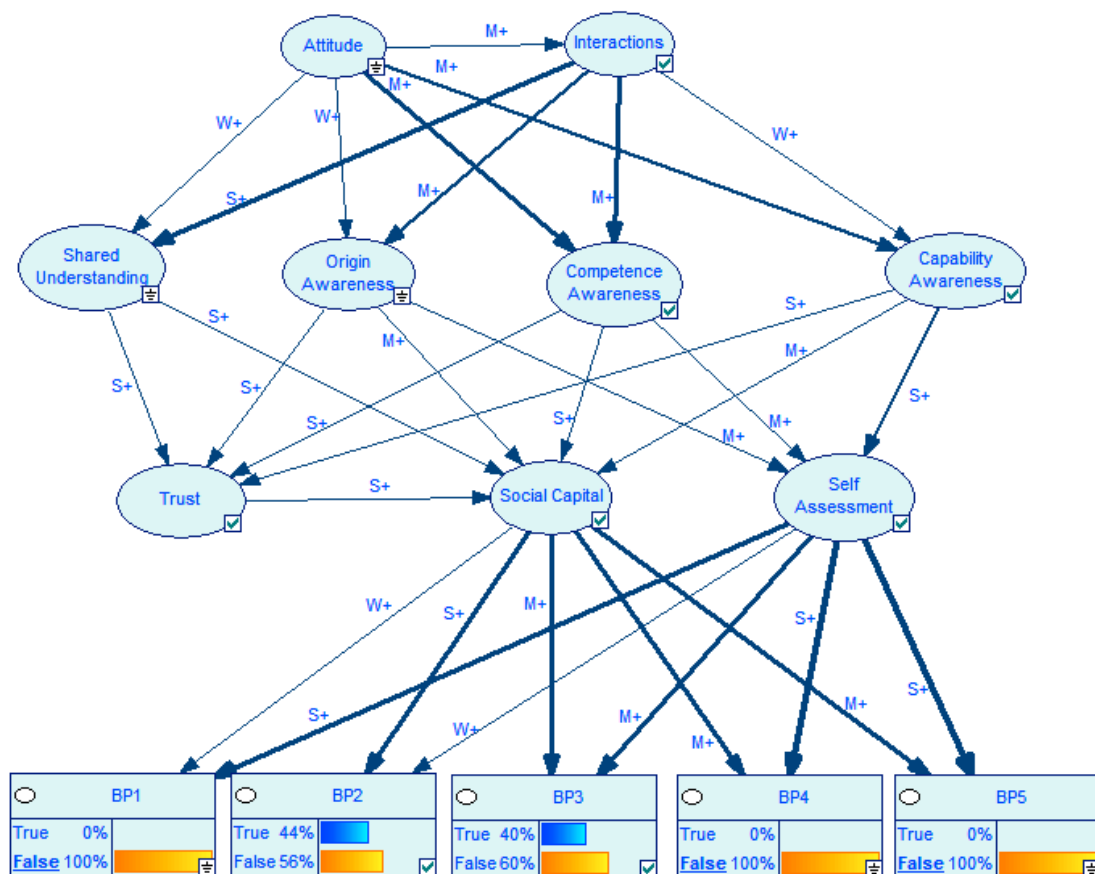
Slika 6-10. Ispitivanje – drugi scenarij, odluka za BP2 ili BP5, 0.



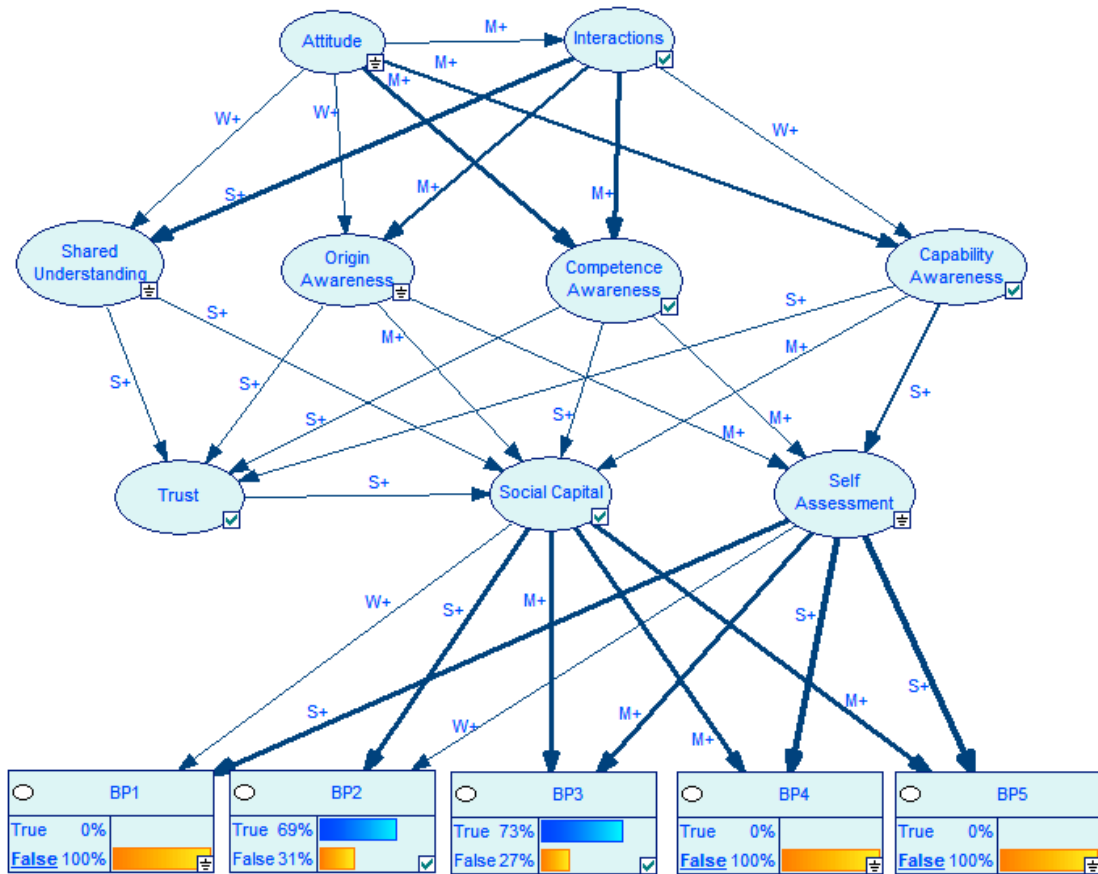
Slika 6-11. Ispitivanje – drugi scenarij, odluka za BP2 ili BP5, competent.



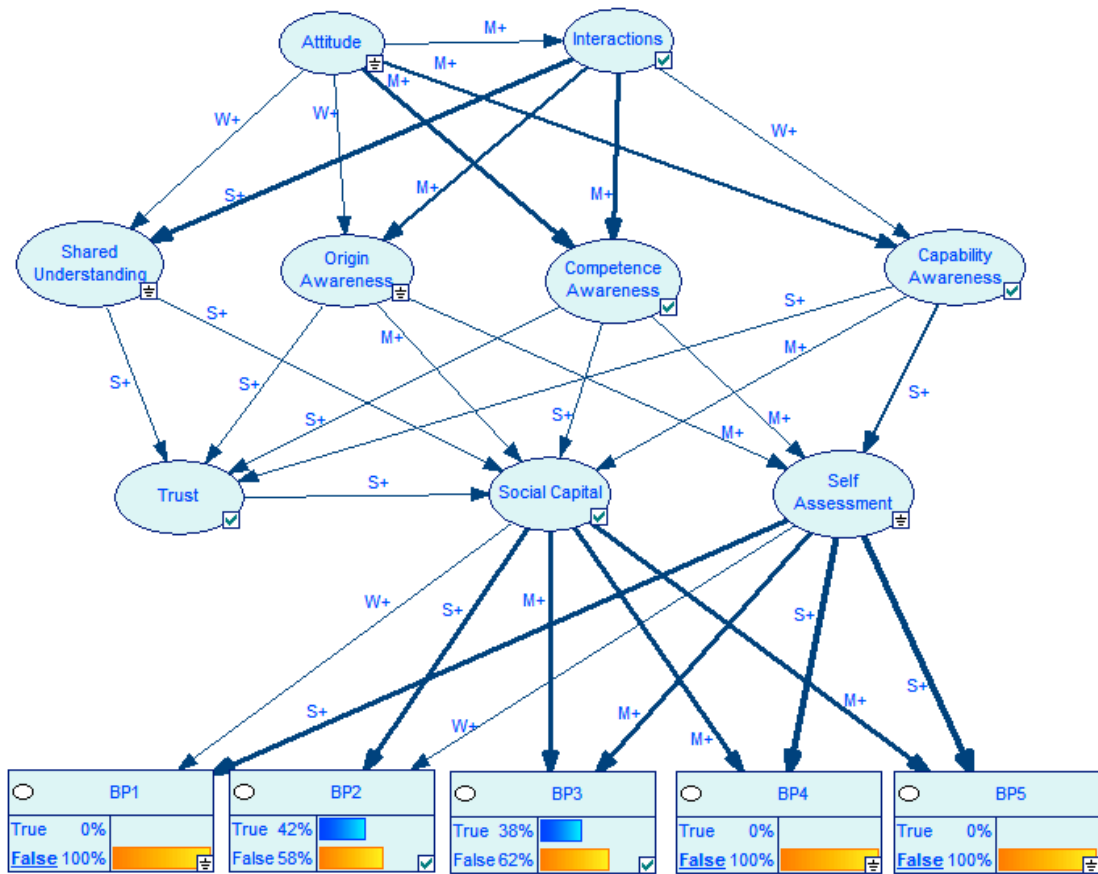
Slika 6-12. Ispitivanje – drugi scenarij, odluka za BP2 ili BP5, incompetent.



Slika 6-13. Ispitivanje – drugi scenarij, odluka za BP2 ili BP3, 0.



Slika 6-14. Ispitivanje – drugi scenarij, odluka za BP2 ili BP3, competent.



Slika 6-15. Ispitivanje – drugi scenarij, odluka za BP2 ili BP3, incompetent.

U sklopu zadnjeg mogućeg slučaja:

- $Query = [[0, 1, 1, 0, 0], 0]$,

u kojem ontološka jezgra sugerira odabir *BP2* ili *BP3*, mreža će bez dokaza o kompetencijama robota predložiti odabir *BP2* kao manje kompleksnog uzorka ponašanja koji rezultira propuštanjem nosača proizvoda (*PC*) do sljedećeg robota u grupi [Slika 6-13]. U slučaju da je robot kompetentan, mreža će procijeniti da je *BP3* bolje rješenje pa će nosač proizvoda (*PC*) biti zadržan na promatranom radnom mjestu [Slika 6-14]. U slučaju da je robot ocijenjen kao nekompetentan, mreža će sugerirati propuštanje nosača proizvoda do sljedećeg robota u grupi odabirom *BP2* [Slika 6-15].

Time je evaluacija rada mreže u sklopu drugog scenarija završena. Mreža je polučila zadovoljavajuće rezultate koji ukazuju na zadovoljavajuće definirano te pohranjeno vjerovanje ljudskog stručnjaka.

6.2. Treći scenarij

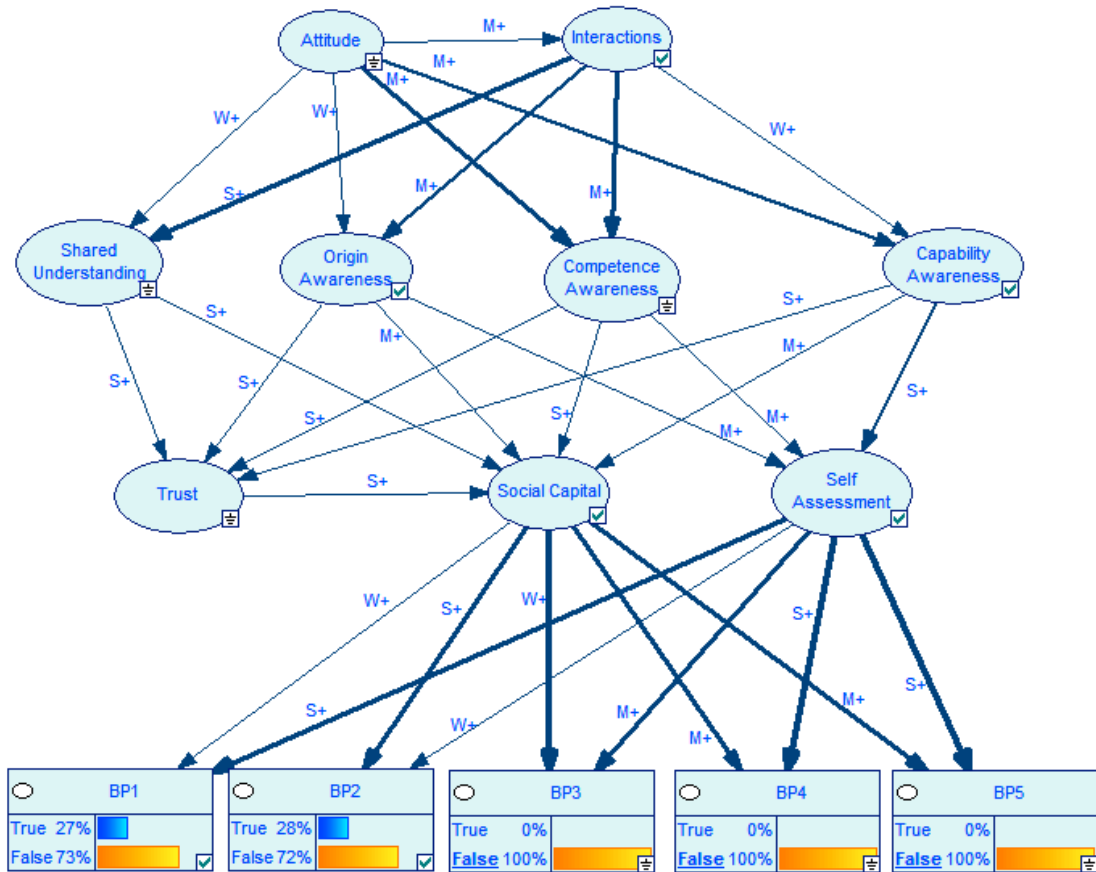
Unutar opisa trećeg scenarija moguće je iščitati sljedeće vrijednosti varijabli mreže:

- *Attitude = negative; Shared Understanding = high; Competence Awareness = present; Trust = low; Self Assessment = 0/competent/incompetent.*

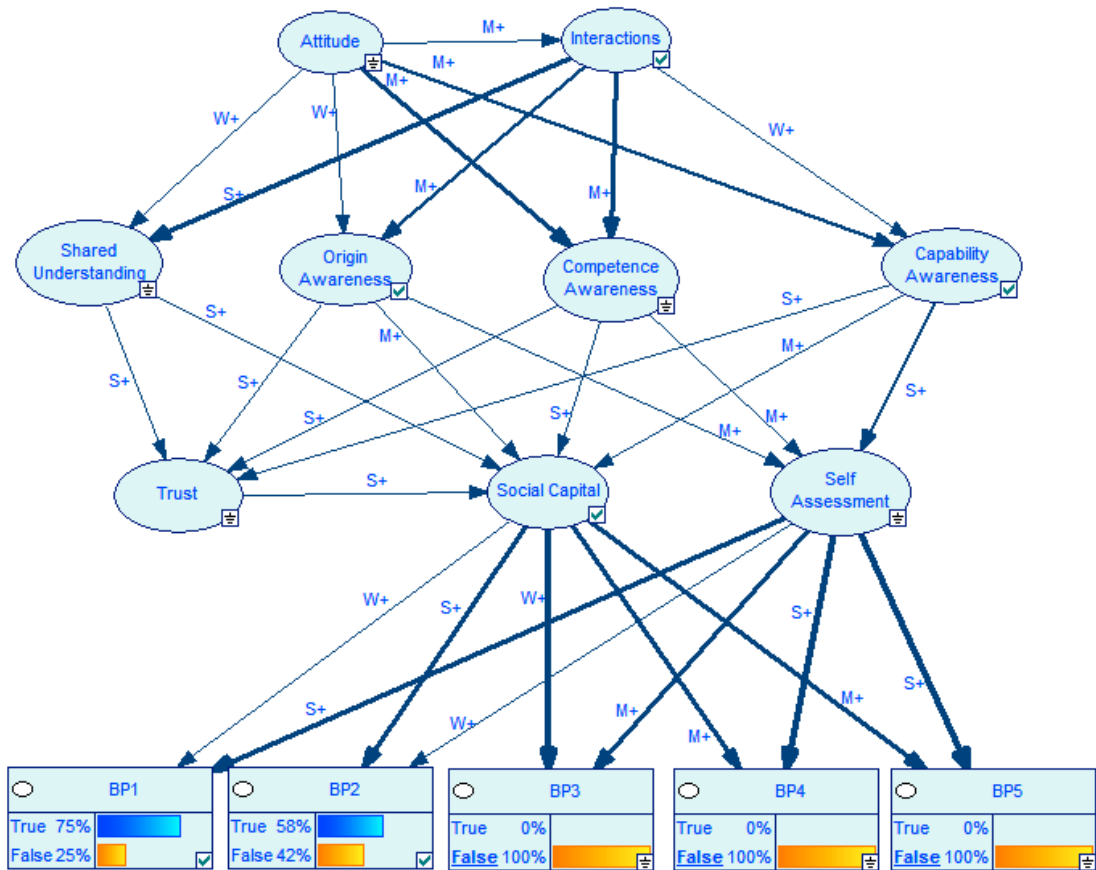
Iako je unutar opisa trećeg scenarija navedena dostatna ekipiranost svih robota u grupi, kod varijable *Self Assessment* radi cjelovitosti rada bit će analizirani dokazi za kompetentno i nekompetentno ocijenjene robote. Slika [Slika 6-16] prikazuje odzive mreže ako je na ulaz doveden upit sljedećeg sadržaja:

- $Query = [[1, 1, 0, 0, 0], 0/imcompetent/competent]$.

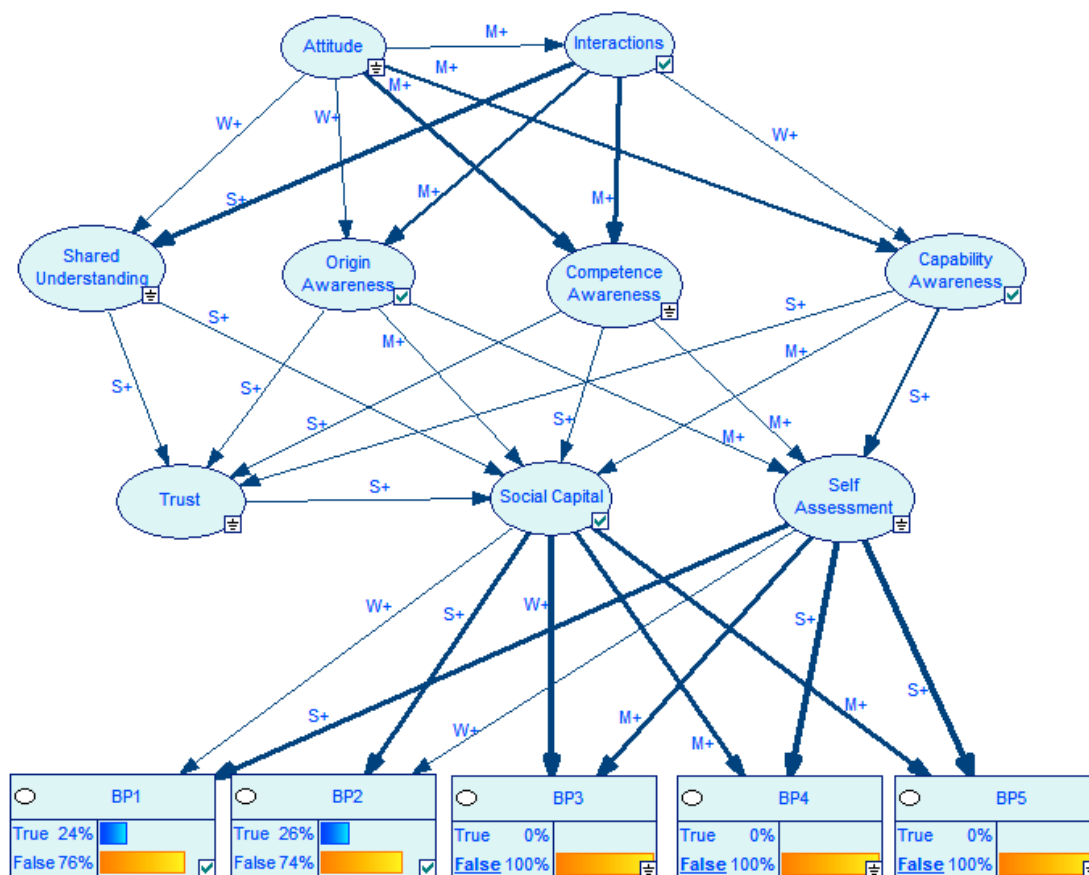
Kao što je moguće vidjeti, u slučaju da nije omogućen dokaz *Self Assessment* mreža će blagu prednost dati *BP2*, odnosno propuštanju nosača proizvoda (*PC*) do sljedećeg robota. Rješenje sugerira da se mreža još uvijek, u nedostatku dokaza o kompetencijama, “oslanja” na kompetencije ostalih robota u grupi. U slučaju da se radi o kompetentnom robotu [Slika 6-17], prevladat će utjecaj *Self Assessment* varijable te će biti odabran uzorak ponašanja *BP1*. Ako se radi o nekompetentnom robotu, mreža će procijeniti da je uzorak ponašanja *BP2* bolje rješenje [Slika 6-18]. To je u skladu s razmišljanjem ljudskog stručnjaka budući da nedovoljno nekompetentan robot ni u kojem slučaju ne može odraditi posao što znači da zadržavanje palete neće biti korisno za sustav.



Slika 6-16. Ispitivanje – treći scenarij, odluka za BP1 ili BP2, 0.



Slika 6-17. Ispitivanje – treći scenarij, odluka za BP1 ili BP2, competent.



Slika 6-18. Ispitivanje – treći scenarij, odluka za BP1 ili BP2, incompetent.

U slučaju da ontološka jezgra Bayesovoj mreži preda upit:

- $Query = [[1, 1, 0, 0, 0], 0/imcompetent/competent]$,

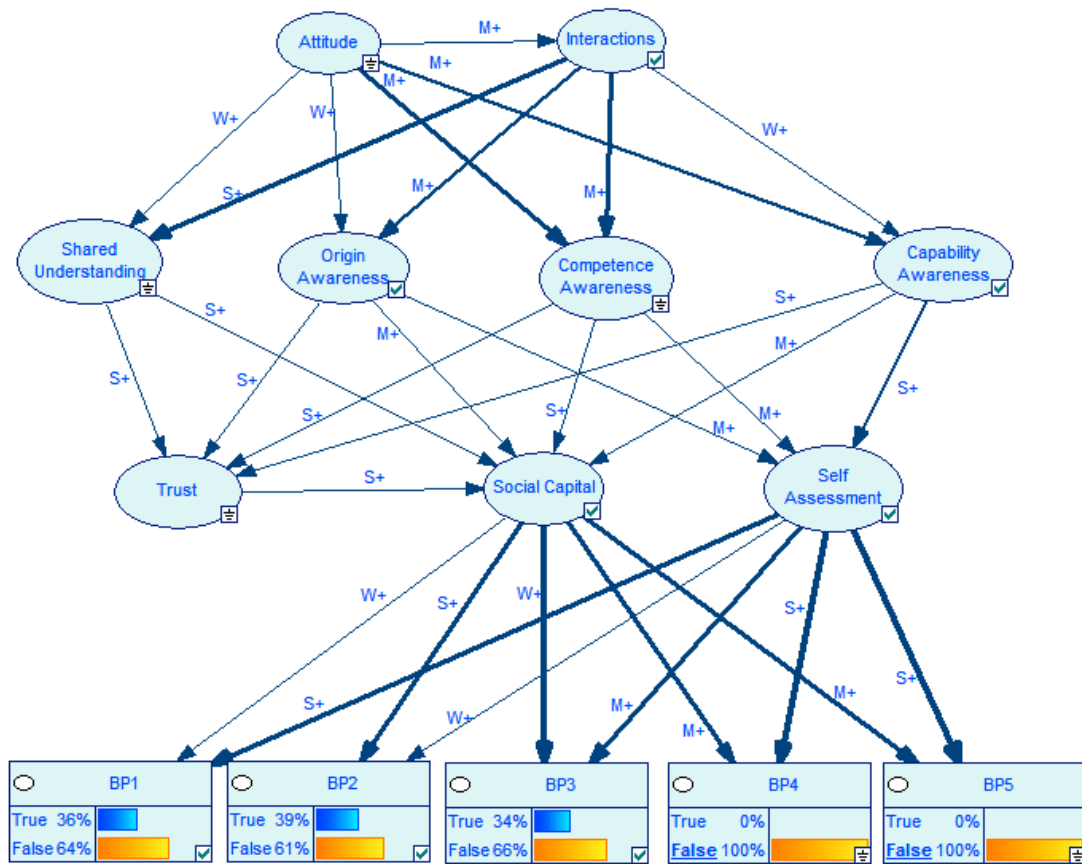
Mreža će biti sklonija kao rješenje odabrati BP2 budući da nisu dostavljeni dokazi o kompetenciji robota koji šalje upit [Slika 6-19]. Nakon što mreža dobije dokaz da je promatrani robot kompetentan bit će odabran uzorak ponašanja BP1 što označava zadržavanje nosača proizvoda i čekanje na promjenu stanja senzora u okolini [Slika 6-20].

Slika [Slika 6-21] prikazuje slučaj kada se radi o nekompetentnom robotu. U tome slučaju mreža sugerira odabir BP2 koji označavanje prosljeđivanje nosača proizvoda (PC) sljedećem robotu u grupi.

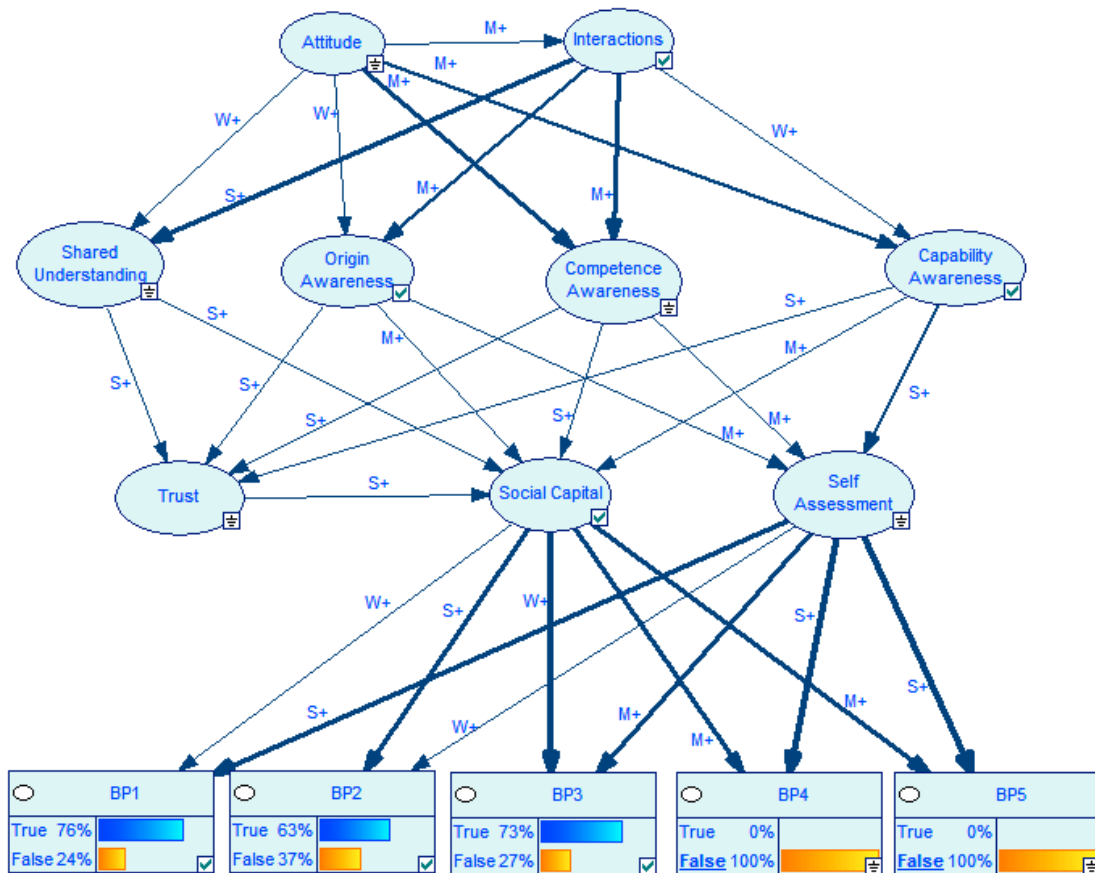
U slučaju da Bayesova mreža kao sastavni dio modela razvijenog u sklopu ovog rada od ontološke jezgre na ulaz dobije upit:

- $Query = [[0, 1, 0, 1, 0], 0/imcompetent/competent]$,

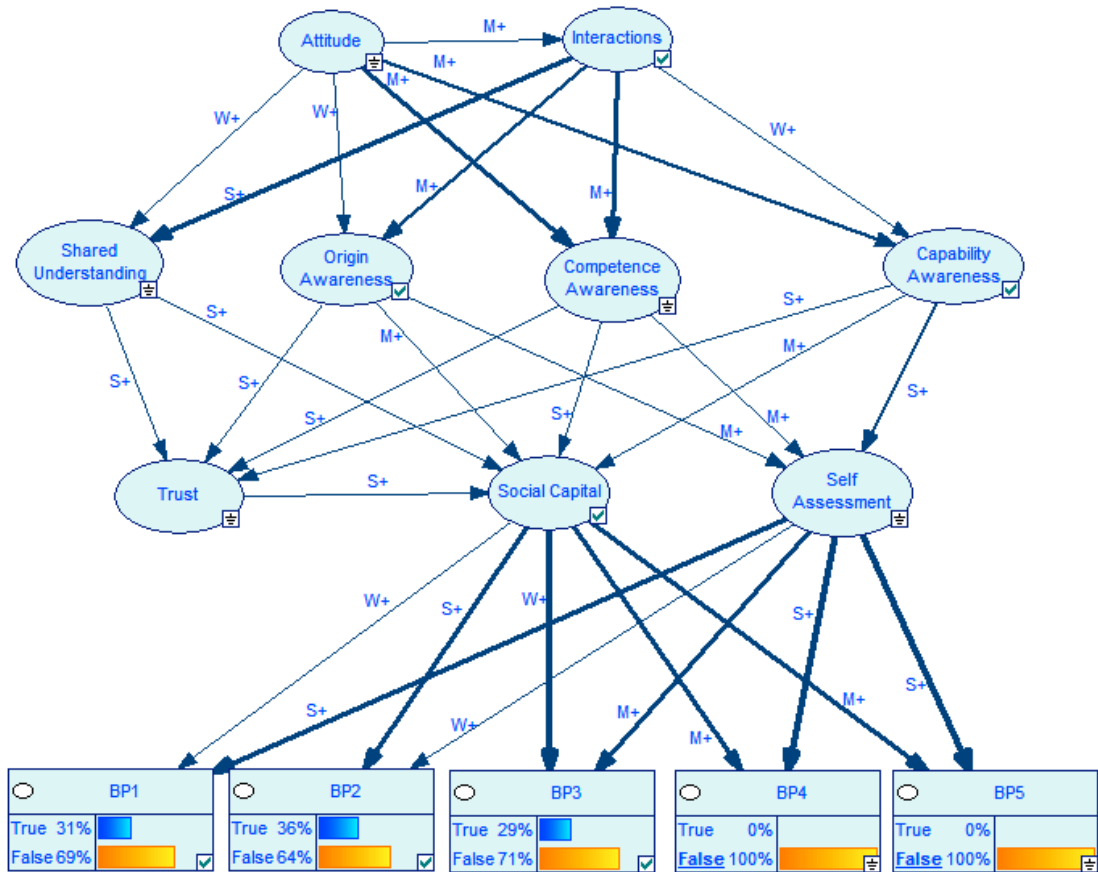
koji odražava neodlučnost odabira ontologije između BP2 i BP4, odlučit će da je povoljnije rješenje BP2 budući da nije dobila dokaz o kompetencijama robota [Slika 6-22]. Ako je informacija o kompetentnosti robota pozitivna, mreža će procijeniti da je BP4 povoljnije rješenje za dane uvijete [Slika 6-23].



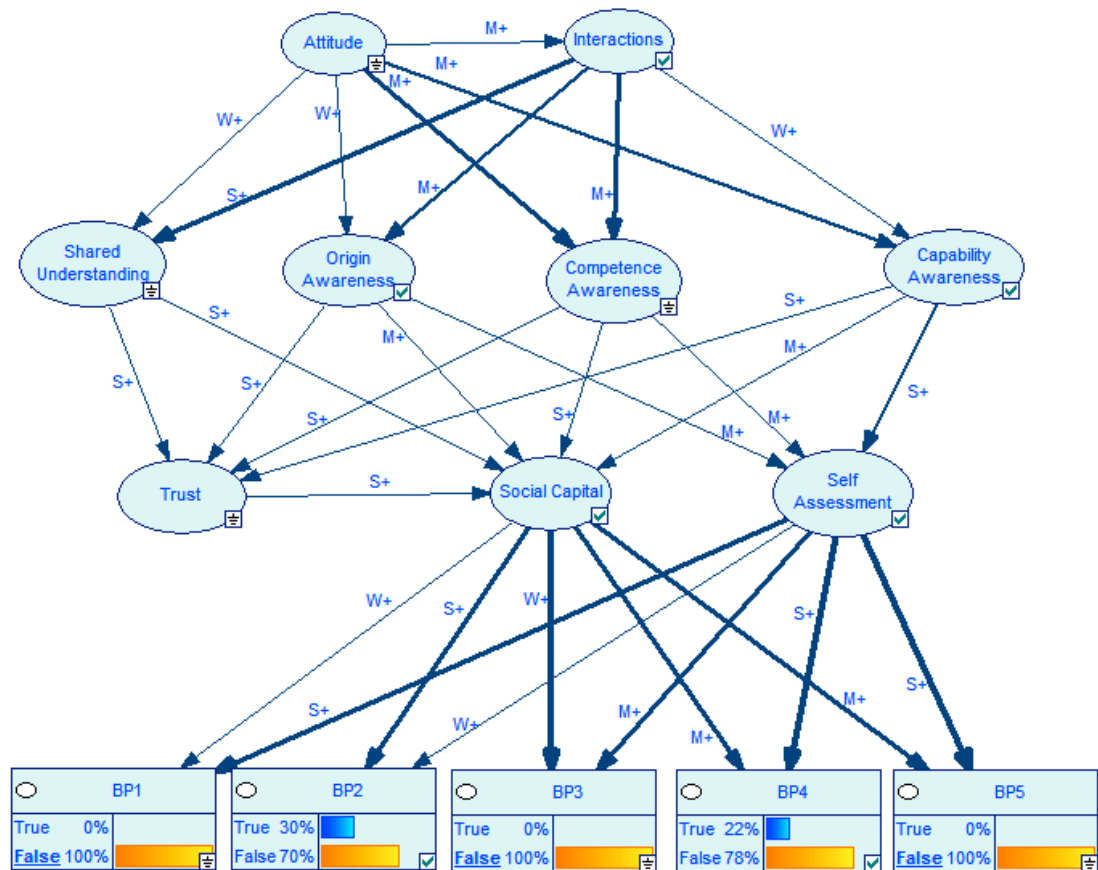
Slika 6-19. Ispitivanje – treći scenarij, odluka za BP1, BP2 ili BP3, 0.



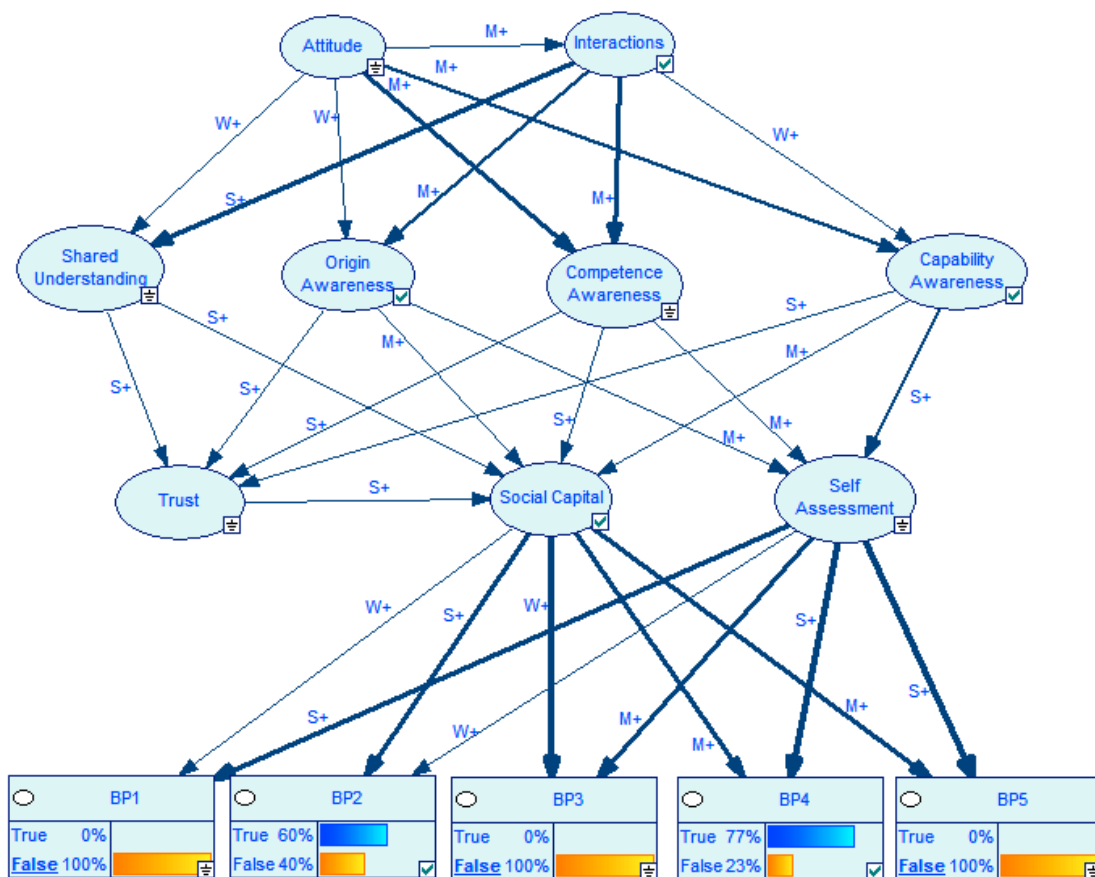
Slika 6-20. Ispitivanje – treći scenarij, odluka za BP1, BP2 ili BP3, competent.



Slika 6-21. Ispitivanje – treći scenarij, odluka za BP1, BP2 ili BP3, incompetent.



Slika 6-22. Ispitivanje – treći scenarij, odluka za BP2 ili BP4, 0.



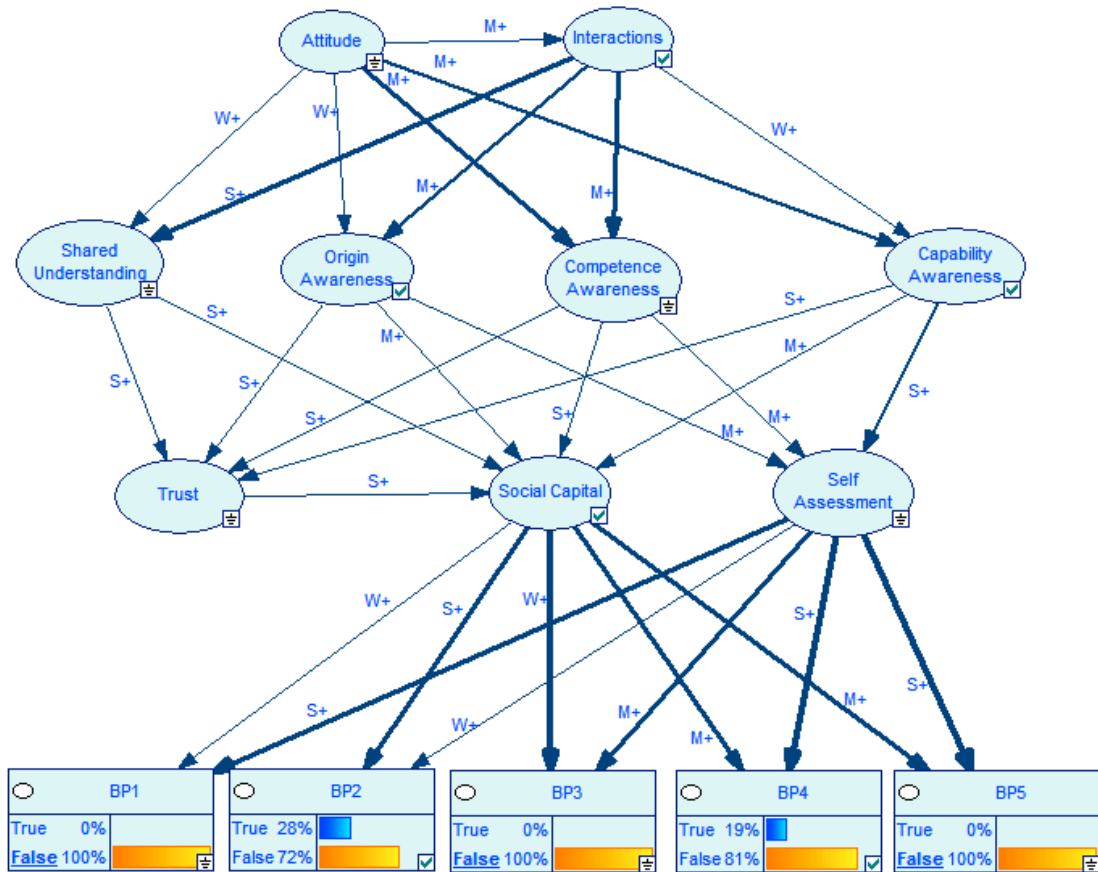
Slika 6-23. Ispitivanje – treći scenarij, odluka za BP2 ili BP4, competent.

U slučaju da mreža prima upit od nekompetentnog robota, kao rješenje će mreža ponuditi BP2, čime će biti osiguran protok nosača proizvoda do robota koji može odgovoriti na zahtjeve svojeg radnog mjesta [Slika 6-24].

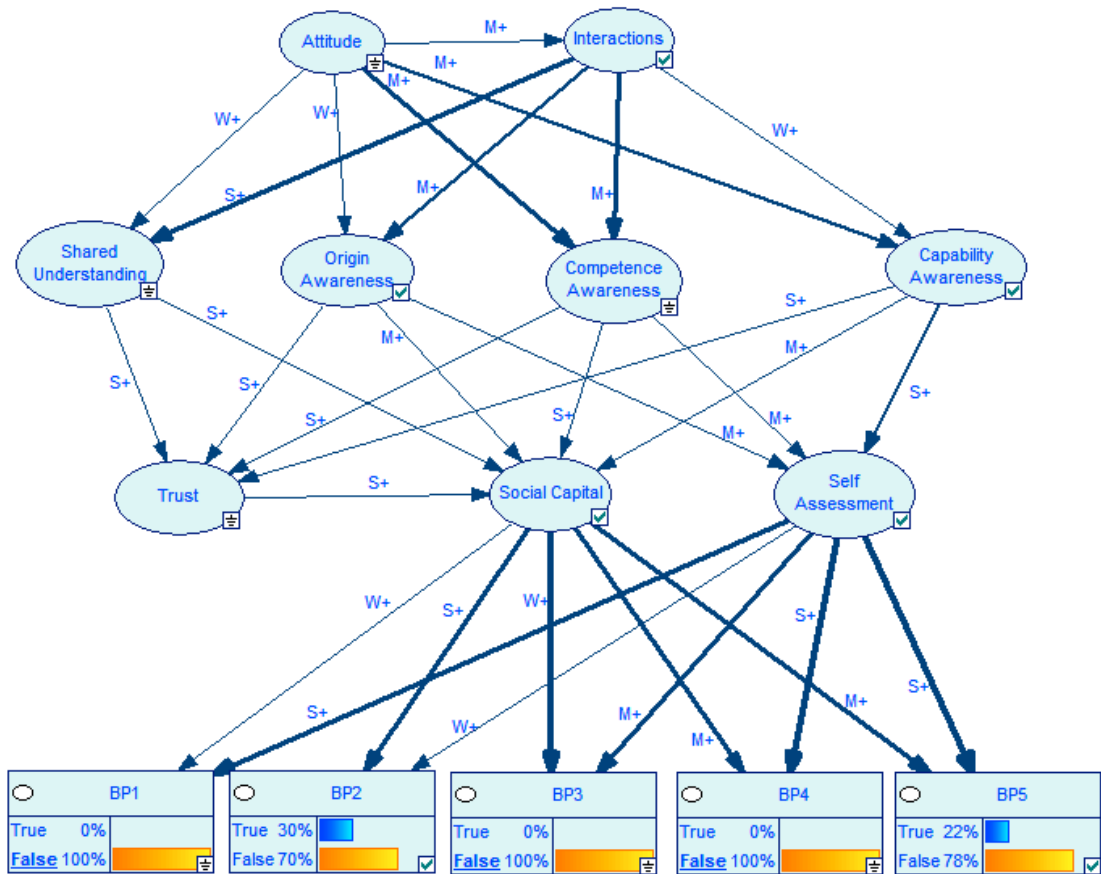
Ako mreža primi upit:

- $Query = [[0, 1, 0, 1, 0], 0/imcompetent/competent]$,

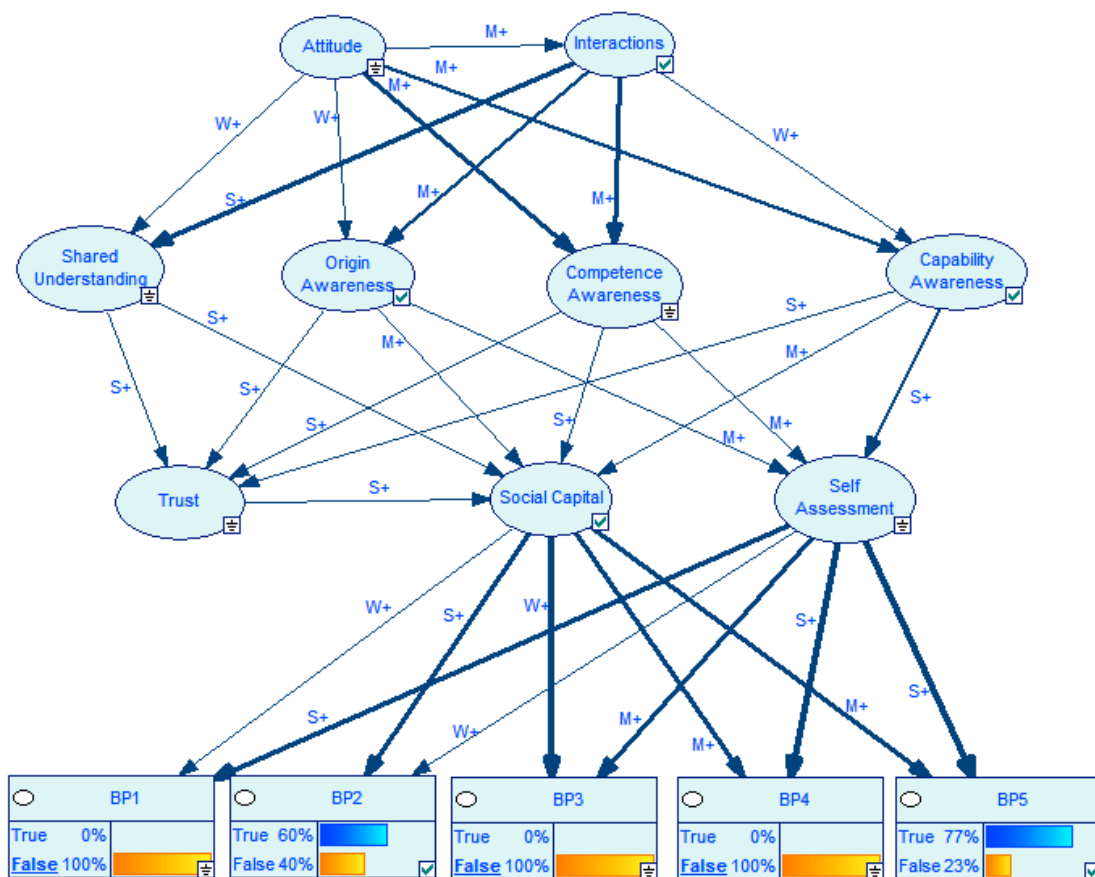
koji sugerira odabir između BP2 i BP5, BP2 će biti procijenjen kao bolji odabir budući da mreži nisu dostavljeni dokazi o kompetencijama robota koji postavlja upit [Slika 6-25]. Ako je upit došao od kompetentnog robota, mreža će procijeniti da je bolje rješenje da robot samostalno nastavi sklapanje proizvoda odabravši BP5 [Slika 6-26]. Za slučaj da je nekompetentni robot postavio upit, mreža će sugerirati odabir BP5 što je u skladu s dosadašnjim ponašanjem u sklopu ovog scenarija [Slika 6-27].



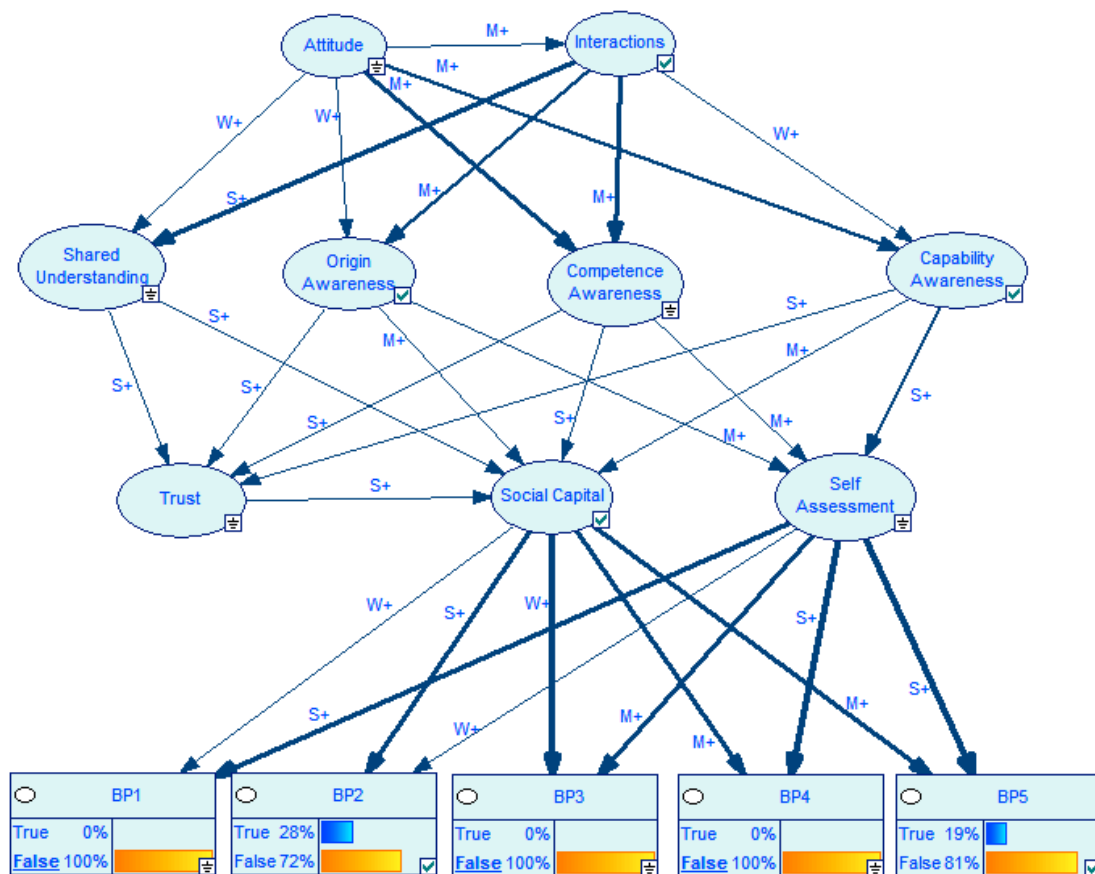
Slika 6-24. Ispitivanje – treći scenarij, odluka za BP2 ili BP4, incompetent.



Slika 6-25. Ispitivanje – treći scenarij, odluka za BP2 ili BP5, 0.



Slika 6-26. Ispitivanje – treći scenarij, odluka za BP2 ili BP5, competent.

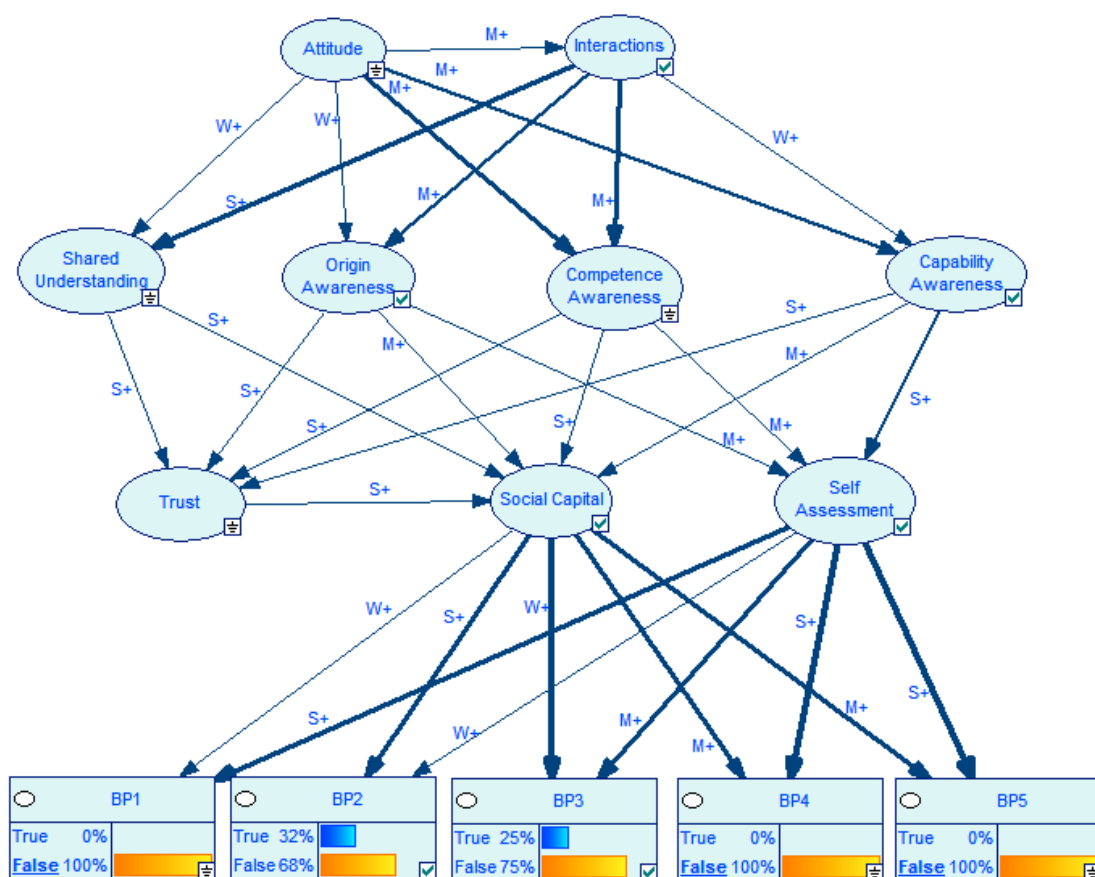


Slika 6-27. Ispitivanje – treći scenarij, odluka za BP2 ili BP5, incompetent.

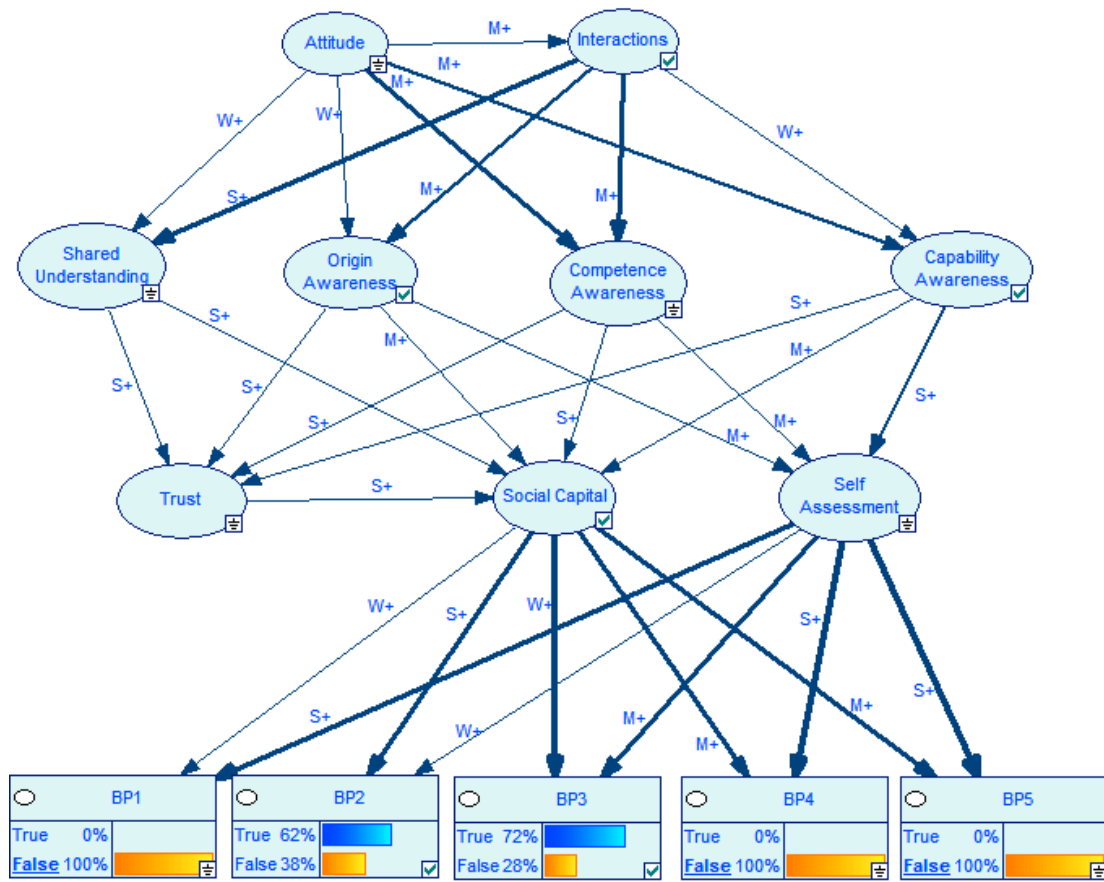
Posljednja moguća kombinacija koju ontološka baza na temelju stanja u okolini može ponuditi, sadrži upit:

- $Query = [[0, 1, 1, 0, 0], 0/imcompetent/competent]$,

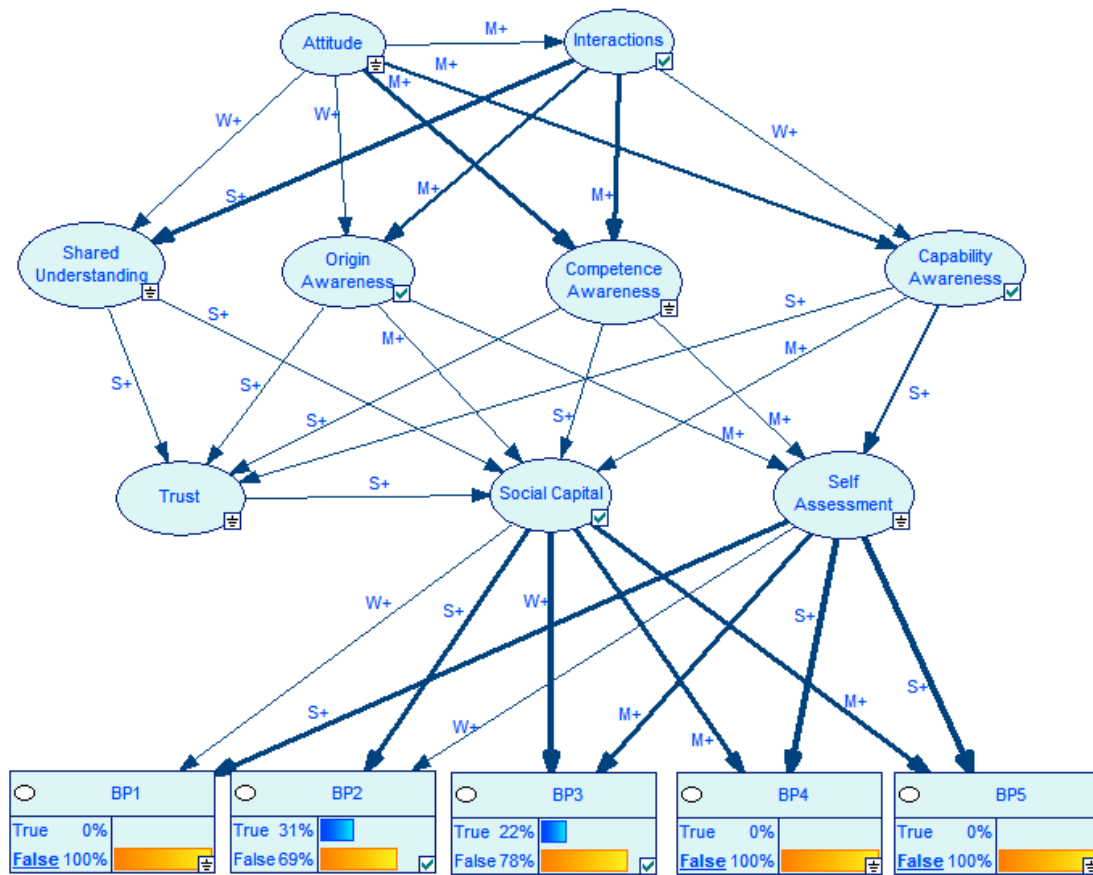
u kojem su *BP2* i *BP3* naznačeni kao moguća rješenja. U slučaju da nedostaje informacija o kompetencijama, mreža će predložiti *BP2* kao rješenje koje osigurava daljnji rad grupe [Slika 6-28]. Ako upit pošalje robot koji je ocijenjen kao kompetentan mreža će tada odabrati *BP3* čime će sugerirati robotu da sam napravi posao u skladu s definicijom trećeg uzorka ponašanja [Slika 6-29]. Ako je upit poslao robot koji je ocijenjen kao nekompetentan, mreža će sugerirati propuštanje nosača proizvoda odabirom uzorka ponašanja *BP2* [Slika 6-30].



Slika 6-28. Ispitivanje – treći scenarij, odluka za BP2 ili BP3, 0.



Slika 6-29. Ispitivanje – treći scenarij, odluka za BP2 ili BP3, competent.



Slika 6-30. Ispitivanje – treći scenarij, odluka za BP2 ili BP3, incompetent.

Na temelju provedene analize moguće je zaključiti da i za slučaj opisan u sklopu trećeg scenarija, Bayesova mreža dosljedno odražava vjerovanja ljudskog stručnjaka koji je razvio spoznajni model.

6.3. Validacija metodologije analizom utjecaja čvorova mreže

Utvrđivanje odgovarajućih parametara uvjetnih i marginalnih vjerojatnosti može se provoditi na više načina. U slučaju da se koriste stvarni podaci, praksa je da se od glavnog skupa odvoji dio podataka koji će biti korišten u fazi ispitivanja mreže (npr. 80% podataka za učenje mreže, a 20% za ispitivanje) [105]. Kako je u sklopu ovog rada izračun vjerojatnosti temeljen na metodi koja koristi težinske faktore utjecaja varijabli roditelja na varijable djeću, Bayesova mreža nije mogla biti ispitana na taj način. U tim slučajevima se mogu koristiti i neke druge metode pomoću kojih se najčešće testira kvantitativni dio Bayesove mreže, npr. analiza osjetljivosti modela na promjene, kritički osvrti na pretpostavke unesene u model, kritički osvrti na proces razvoja modela, sposobnost modela da daje suvisle odgovore u slučajevima nemogućih dokaza i sl. [106].

Analiza osjetljivosti (engl. *Sensitive Analysis*) je matematička metoda pomoću koje se utvrđuje jesu li neke od varijabli matematičkog modela nedovoljno točne, odnosno jesu li pogrešno definirane. Prilikom provedbe metode postoje dva pristupa koji se koriste u ovisnosti ciljevima ispitivanja. U prvom se provodi ispitivanje osjetljivosti mreže na globalnoj razini. Mreži se mijenjaju vrijednosti parametara te se promatraju utjecaji tih promjena na zaključivanje. U sklopu drugog pristupa, koji je korišten u ovom radu, provodi se analiza čvorova na način da ih se dovede u vezu s upitnim čvorovima (engl. *Query Nodes*). Vjerovanja koja se iskazuju kroz ovaj tip čvorova u ovisnosti o namjeni mreže mogu se koristiti prilikom donošenja odluka (u ovom radu su to varijable uzoraka ponašanja). U upitnim čvorovima analizira se zaključivanje koje je manifestirano kroz mrežu. Stoga se prilikom provođenja analize promatra utjecaj pojedine varijable unutar mreže na zbirnu vrijednost manifestiranu unutar upitnog čvora. Na taj su način u sklopu analize Bayesove mreže zasebno razmatrani svi upitni čvorovi.


Jedna od mjera za validaciju zaključivanja koja je korištena u ovom radu je smanjenje entropije (engl. *Entropy Reduction*). Ovaj tip entropije, koji svoje korijene vuče iz informacijskih znanosti [107], predstavlja mjeru za iskazivanje nesigurnosti. Smanjenje entropije omogućit će informacije o tome koliko pojedini čvor utječe na upitni s gledišta smanjenja nesigurnosti.

Budući da Bayesova mreža unutar spoznajnog modela može generirati beskonačno puno procjena izlaznih varijabli u ovisnosti o dokazima i vjerovanjima implementiranim u ostale varijable, uporaba analize osjetljivosti pokazala se opravdanom. Pomoću nje je moguće otkriti sakrivene, relativne utjecaje među varijablama te pomoću njih probati utjecati na ishode zaključivanja mreže.


Analiza osjetljivosti je provedena pomoću *Netica* softverskog paketa [108] koji u sebi uključuje alate za razvoj i ispitivanje mreže. Analizom su utvrđeni rasponi vrijednosti težinskih faktora unutar kojih je moguće vršiti daljnja podešavanja te pratiti promijene na globalnoj razini [Slike 6-31 – 6-40]. Rezultati pokazuju da oni čvorovi s niskom razinom utjecaja na upitne čvorove iskazuju niske vrijednosti. Tako su upitni čvorovi (*BP1*, ..., *BP5*) te čvorovi *Social Capital*, *Trust*, *Self Assessment*, *Capability Awareness* i *Competence Awareness* relativno osjetljivi na promatrani upitni čvor u usporedbi s čvorovima *Interaction*, *Attitude*, *Origin Awareness* i *Shared Understanding*. Generalno gledajući, analiza osjetljivosti je pokazala da upitni čvorovi nisu osjetljivi samo na jednu varijablu već na više njih. Osim čvorova *Social Capital* i *Self Assessment*, zamjetan je i utjecaj koji upitni čvorovi imaju jedni na druge. To upućuje na zaključak da je važno koje je uzorke ponašanja ontološka jezgra ponudila kao rješenje, a koje ne. Dokaz koji govori o tome da je neki uzorak ponašanja proglašen kao nemoguć kao odgovor na dano stanje u okolini (*false*), direktno ima utjecaja na zaključivanje u promatranom čvoru.

Provedenom analizom je utvrđeno da najjači utjecaj imaju oni čvorovi koji koriste snažne, pozitivne veze prema ostalim čvorovima (*S+*). Također, postoje barem četiri relativno visoke vrijednosti smanjenja entropije (*BP4*, *BP5*, *Social Capital* i *Self Assessment*) kod čvorova koji posjeduju snažne veze s čvorovima djecom, što upućuje na generalni zaključak da je metodologija određivanja početnih uvjetnih vjerojatnosti u mreži ispravna.

Osim za pronalaženje preciznijih vrijednosti, analiza je provedena i s ciljem da se za vrijeme implementacije spoznajnog modela na realnom sustavu, promjenom parametara utječe na odluke koje proizlaze iz upitnih čvorova (npr. promjenom vrijednosti praga prilikom određivanja težinskih faktora). Promjene parametara je moguće provoditi sve dok vrijednosti ostaju unutar metodom postavljenih granica.



Slika 6-31. Osjetljivost BP1 (True) - zaključivanje na ostalim čvorovima.




Slika 6-32. Smanjenje entropije BP1 - utjecaji pojedinog čvora.

Tablica 6-1. BP1 (True) – prostor vrijednosti vjerojatnosti.


	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Maks.	1	0.6992	0.7067	0.7177	0.7177	0.7061	0.781	0.6818	0.6785	0.6858	0.6831	0.6995	0.6779	0.6761
Trenutno.	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666	0.6666
Min.	0	0.5913	0.5782	0.523	0.523	0.5103	0.469	0.6019	0.6376	0.6322	0.6269	0.6099	0.6405	0.629

Tablica 6-2. BP1 (True) – smanjenje entropije.

	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Smanjenje entropije	100	0.853	1.23	2.51	2.51	2.09	7.89	0.34	0.121	0.231	0.653	0.229	0.103	0.124



Slika 6-33. Osjetljivost BP2 (True) - zaključivanje na ostalim čvorovima.



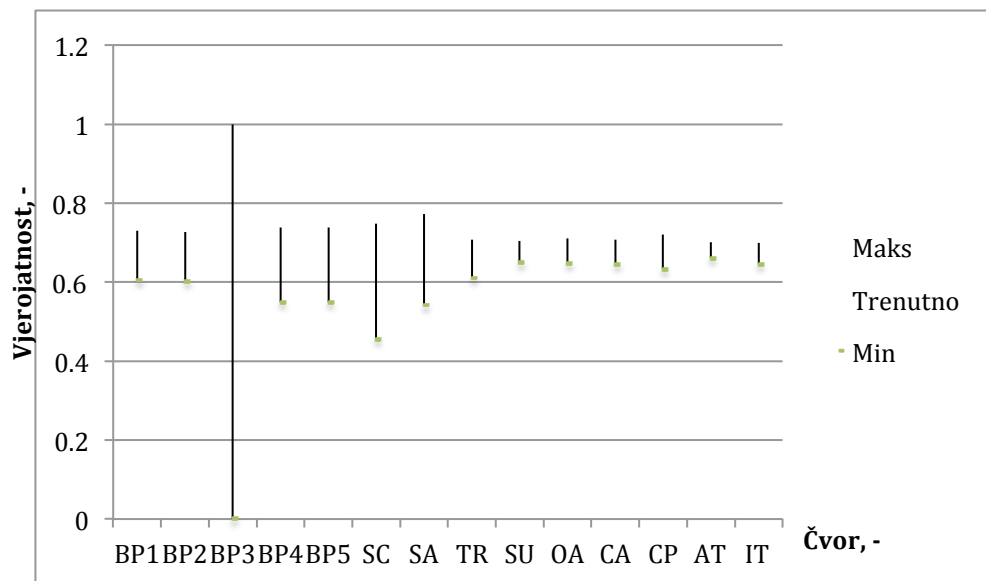
Slika 6-34. Smanjenje entropije BP2 - utjecaji pojedinog čvora.

Tablica 6-3. BP2 (True) – prostor vrijednosti vjerojatnosti.


	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Maks.	0.7321	1	0.7363	0.7427	0.7427	0.7725	0.7468	0.7187	0.7177	0.7229	0.7175	0.7281	0.7107	0.7102
Trenutno.	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698	0.698
Min.	0.6298	0	0.6134	0.5723	0.5723	0.4026	0.6137	0.61	0.6498	0.6532	0.651	0.646	0.6685	0.6492

Tablica 6-4. BP2 – smanjenje entropije.

	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Smanjenje entropije	0.886	100	1.22	2.09	2.09	7.93	1.57	0.679	0.362	0.428	0.35	0.6	0.144	0.226



Slika 6-35. Osjetljivost BP3 (True) - zaključivanje na ostalim čvorovima.




Slika 6-36. Smanjenje entropije BP3 - utjecaji pojedinog čvora.

Tablica 6-5. BP3 (True) – prostor vrijednosti vjerojatnosti.


	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Maks.	0.7299	0.7264	1	0.7381	0.7381	0.7476	0.773	0.7072	0.705	0.7114	0.7072	0.7212	0.701	0.6998
Trenutno.	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886	0.6886
Min.	0.606	0.6014	0	0.5493	0.5493	0.455	0.5428	0.6096	0.6487	0.6476	0.6437	0.6324	0.6598	0.6439

Tablica 6-6. BP3 – smanjenje entropije.

	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Smanjenje entropije	1.26	1.21	100	2.5	2.5	4.87	4.54	0.534	0.242	0.348	0.31	0.682	0.133	0.185



Slika 6-37. Osjetljivost BP4 (True) - zaključivanje na ostalim čvorovima.




Slika 6-38. Smanjenje entropije BP4 - utjecaji pojedinog čvora.

Tablica 6-7. BP4 (True) – prostor vrijednosti vjerojatnosti.


	<i>BP1</i>	<i>BP2</i>	<i>BP3</i>	<i>BP4</i>	<i>BP5</i>	<i>SC</i>	<i>SA</i>	<i>TR</i>	<i>SU</i>	<i>OA</i>	<i>CA</i>	<i>CP</i>	<i>AT</i>	<i>IT</i>
Maks.	0.7943	0.785	0.7908	1	0.8036	0.8061	0.863	0.7606	0.7572	0.766	0.7808	0.7612	0.7535	0.7516
Trenutno	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378
Min.	0.6248	0.6286	0.6205	0	0.5525	0.4669	0.5214	0.6406	0.6904	0.6869	0.6636	0.6811	0.7011	0.6823

Tablica 6-8. BP4 – smanjenje entropije.

	<i>BP1</i>	<i>BP2</i>	<i>BP3</i>	<i>BP4</i>	<i>BP5</i>	<i>SC</i>	<i>SA</i>	<i>TR</i>	<i>SU</i>	<i>OA</i>	<i>CA</i>	<i>CP</i>	<i>AT</i>	<i>IT</i>
Smanjenje entropije	2.78	2.23	2.69	100	5.15	7.55	11.9	0.947	0.404	0.635	0.584	1.41	0.255	0.335



Slika 6-39. Osjetljivost BP5 (True) - zaključivanje na ostalim čvorovima.



Slika 6-40. Smanjenje entropije BP5 - utjecaji pojedinog čvora.

Tablica 6-9. BP5 (True) – prostor vrijednosti vjerojatnosti.

	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Maks.	0.7943	0.785	0.7908	0.8036	1	0.8061	0.863	0.7606	0.7572	0.766	0.7612	0.7808	0.7535	0.7516
Trenutno	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378	0.7378
Min.	0.6248	0.6286	0.6205	0.5525	0	0.4669	0.5214	0.6406	0.6904	0.6869	0.6811	0.6636	0.7011	0.6823

Tablica 6-10. BP5 – smanjenje entropije.

	BP1	BP2	BP3	BP4	BP5	SC	SA	TR	SU	OA	CA	CP	AT	IT
Smanjenje entropije	2.78	2.23	2.69	5.15	100	7.55	11.9	0.947	0.404	0.635	0.584	1.41	0.255	0.335

“ *THE EDGE, there is no honest way to explain it because the only people who really know where it is are the ones who have gone over.* ”

Hunter S. Thompson

U disertaciji je razvijen spoznajni model koji omogućuje zajednički rad grupe robota unutar industrijske radne okoline na poslovima sklapanja proizvoda. Da bi odluke bile temeljene na kontekstualnoj spoznaji, model koristi semantički opis domene interesa te Bayesovu mrežu za donošenje jednoznačnih i nedvosmislenih odluka.

Semantički opis sadrži ontologiju napisanu *OWL-om* koja se pokazala kao pogodan medij za pohranu, dijeljenje te ponovno korištenje znanja o domeni interesa. U skladu sa svojom prirodom, te na temelju znanja o domeni interesa i informacijama iz okoline koje su prikupljene pomoću senzora, ontološka jezgra može ponuditi jedno ili više rješenja u vidu, tzv. uzoraka ponašanja (engl. *Behavioral Patterns*). Uzorci ponašanja predstavljaju skup operacija koje su ostvarene kroz pet algoritama koje robot može izvršavati kao odgovor na trenutno stanje u okolini. U slučaju da ontologija ponudi više mogućih rješenja (istovremeno dva ili više uzoraka ponašanja), odluku o konačno odabranom algoritmu donosi Bayesova mreža koristeći vjerovanja o procijenjenom socijalnom kapitalu grupe, te vjerovanje o kompetentnosti robota koji postavlja upit.

Prilikom razvoja ontološke jezgre vođeno je računa o minimalnoj kompleksnosti kako bi se taj dio modela učinio što preglednijim, lakšim za održavanje i nadogradnju, te kasniju implementaciju na realnim sustavima. Stoga je dio logičkih operacija prebačen na *SPARQL* jezik pomoću kojeg se šalju upiti ontološkoj jezgri. Time je olakšana integracija ontologije u sklopu web poslužitelja budući da web tehnologija kasni za razvojem te stoga podrška za kompleksnije ontologije nije uvijek zadovoljavajuća. Također, vođeno je računa o kompatibilnosti ontološke jezgre modela s drugim sličnim ontologijama koje opisuju domene proizvodnih djelatnosti i koje se trenutno razvijaju ili tek čekaju da budu razvijene.

Bayesova mreža, koja predstavlja temelj probabilističkog zaključivanja integriranog unutar spoznajnog modela, inspirirana je fenomenom socijalnog kapitala identificiranog kod stvarnih ljudskih zajednica. Socijalni kapital označava potencijal grupe da zajednički radi na ostvarivanju nekog zajedničkog cilja. U sklopu spoznajnog modela, varijable koje predstavljaju čvorove Bayesove mreže karakteriziraju grupu robota s gledišta socijalnog kapitala generirajući pritom vrijednosti koje odražavaju potencijal grupe za zajednički rad na poslovima sklapanja. Varijable su međusobno povezane vezama koje označavaju snagu utjecaja varijabli roditelja na varijable djecu. Kao protuteža procijenjenom socijalnom kapitalu kreirana je varijabla samoprocijene u kojoj je uključena ocjena ljudskog stručnjaka u kompetencije robota koji postavlja upit. Na taj način zaključivanje implementirano unutar Bayesove mreže pronalazi jedinstveno rješenje ukoliko ontološka jezgra postavi upit koji sadrži više mogućih rješenja (uzoraka ponašanja). Kroz postupak evolucije koji uključuje i ispitivanje, ovaj dio spoznajnog modela je ostvaren kroz tri različita scenarija. Pokazano je da mreža vraća odzive koji su u skladu s očekivanjima ljudskog stručnjaka, kreatora mreže. Odzivi su pokazali da odabrana rješenja variraju u skladu s različitim vjerovanjima u razinu socijalnog kapitala u ovisnosti o trenutnoj samoprocijeni. Ostvareni pristup se može usporediti s pristupom koji ima čovjek koji donosi odluke u ovisnosti o karakteristikama grupe čiji je član. Ukoliko su kompetencije grupe male, ili je povjerenje u grupu nisko, čovjek će se radije pouzdati u vlastite kompetencije te samostalno krenuti rješavati zadatak. Ukoliko je socijalni kapital njegove grupe ocijenjen visoko, on će se radije pouzdati u intelektualne i sve druge resurse svoje grupe. U tome slučaju sinergija rješenja može dati rezultate koji su bolji nego u slučaju da je osoba cijeli posao napravila sama. Poglavlje koje sadrži validaciju i verifikaciju predložene metodologije pokazuje da razvijeni spoznajni model daje rješenja koja su u skladu s prethodnim razmatranjima. Da bi se istražila snaga utjecaja varijabli na upitne čvorove provedena je analiza osjetljivosti koja mjeri smanjanje entropije. Entropija predstavlja mjeru za nesigurnosti unutar čvorova mreže. Smanjenje entropije pokazuje utjecaj pojedinog čvora na promatrani upitni čvor s gledišta smanjenja nesigurnosti. Kao što je moguće zaključiti uzevši u obzir rezultate analize, najveći utjecaj na upitne čvorove (*BPI*, ... *BP5*) imaju varijable *Self Assessment* i *Socijal Capital*. To je u skladu s očekivanjima budući da te varijable predstavljaju čvorove u kojima se odražavaju vjerovanja ostvarena kroz sve ostale utjecajne faktore. Također, utvrđeni su relativno veliki utjecaji ostalih upitnih čvorova na donošenje jednoznačne odluke mreže. Kao što je ispitivanje mreže pokazalo, mreža će svoje odluke prilagoditi dokazima o trenutnom stanju i kompetencijama grupe. Ukoliko je

grupa robota preko varijabli mreže lošije ocijenjena, vjerojatnije je da će se robot pouzdati u vlastite kompetencije te samostalno izvršavati postavljene zadatke.

U skladu s navodima iz hipoteze, moguće je zaključiti da je razvijeni spoznajni model:

- formalan, budući da je napisan jezikom koji je razumljiv svim komponentama sustava jer izlazne vrijednosti predstavljaju informacije koje nije potrebno dodatno prevoditi kako bi bile razumljive,
- prilagodljiv, budući da omogućuje odabir i/ili promjenu obrazaca ponašanja u odnosu na trenutni kontekst i fazu izvođenja zadataka,
- te zajednički, jer ga koriste sve komponente sustava.

Razvijena metodologija verificirana je, s ciljem potvrde hipoteze koristeći fizičko simulacijsko okruženje na osobnom računalu uz korištenu programsku podršku koja uključuje softver za izradu i ispitivanje ontološke jezgre (*TopBraid Composer*), te softver za razvoj i ispitivanje Bayesove mreže (*Genie&Smile*) [109]. Trenutno se prijenos parametara između komponenti modela izvodi ručno, uz unošenje vrijednosti mogućih stanja iz okoline na ulaz u model te prijepisom izlaznih informacija o obrascima ponašanja na ulaz Bayesove mreže. Budući razvoj modela će uključivati izradu softversku arhitekture opisane pod petom točkom. Izvedena softverska arhitektura će se moći usporediti s, tzv. crnom kutijom (engl. *black box*) koja na jednom kraju prima ulazne informacije dok na drugom kraju daje konačno i jedinstveno rješenje. Daljnji razvoj će se kretati prema razvoju sučelja za unos podataka, odnosno parametara u ontološku jezgru, odnosno Bayesovu mrežu, respektivno.

Razvojem spoznajnog modela ostvareno je više ciljeva. Deterministički kaos koji karakterizira našu prirodno neuređenu okolinu neizbježno ometa naša apsolutna očekivanja, na način da konstantno stvara drugačije situacije. Jedan od pristupa kako to ublažiti je da se deterministički kaos prihvatiti kao prirodni fenomen. U tome slučaju, ovaj rad favorizira razvoj inteligentnih sustava koji su sposobni prilagoditi se okolini u ovisnosti o skali promatranja gdje ništa nije idealno, odnosno apsolutno precizno definirano. U sklopu konvencionalnih rješenja teži se ka stvaranju tehničkih sustava naizgled savršenih konstrukcije u sklopu kojih se nastoje predvidjeti sve moguće varijacije koje okolina može nametnuti. S gledišta prilagodljivosti, čini se da takav pristup vodi kao skupim i relativno neefikasnim rješenjima. Navedena problematika koja je identificirana kod velikog broja svjetskih industrijskih postrojenja vodi ka manjku prostora te krutosti proizvodnih sustava. Ti problemi su još naglašeniji u Europi. Kako napraviti da sustav bude prilagodljiv, da zauzima relativno malo mjesta, da je jeftin i pouzdan zahtjevi su tržišta koji su se pojavili prije više godina. Sveprisutno računarstvo, koje predstavlja treću eru u razvoju računarstva, omogućilo

je integraciju računala (robotu) u okolinu koja se konstantno propitkuje. Ovaj pristup omogućuje stvaranje aplikacija koje su u ovisnosti o namjeni u manjoj ili većoj mjeri svjesne konteksta. Sustav koji svoje odluke temelji na kontekstualnoj spoznaji može se prilagoditi relativno jednostavno da radi različite zadatke u odnosu na klasične industrijske proizvodne linije. Spoznajni model razvijen u sklopu ovog rada može omogućiti robotu da djelomično interpretira i razumije kontekst da bi prilagodio svoje strategije kako bi efektno radio kao dio grupe na novim zadacima. Znanje koje je integrirano u model je prenosivo, odnosno može biti dijeljeno, mijenjano te ponovno korišteno na različitim aplikacijama uz određene modifikacije.

Budući da ovaj rad sadrži razvijeni spoznajni model koji je ispitan kroz tri scenarija, konačna praktična potvrda treba uslijediti u sklopu budućih istraživanja te u primjeni modela na stvarnim aplikacijama. Stoga će i cjelovitije vrednovanje modela uslijediti naknadno. U sklopu disertacije su provedene validacija i verifikacija gdje su identificirane maksimalne i minimalne vrijednosti težinskih faktora Bayesove mreže. To znači da je unutar tih granica moguće mijenjati vrijednosti kako bi se ponašanje modela prilagodilo stvarnom stanju. Također, taksonomija ontološke jezgre modela sadrži tek dio opisa opreme, operacija i procesa koji prema svojim karakteristikama pripadaju unutar metodologije sklapanja proizvoda. To je proizašlo iz činjenice da je više autora dalo svoje viđenje semantičkog opisa proizvoljnih djelatnosti od čega je u sklopu ovog rada napravljen presjek i nadogradnja prema subjektivnom viđenju stručnjaka koje opisuje metodologiju sklapanja. Cilj ovog rada nije bio razvoj ontologije koja u detalje i potpuno objektivno opisuje domenu interesa. Hipoteza rada uključuje razvoj spoznajnog modela koji robotu unutar grupe omogućuje donošenje odluka temeljenih na kontekstu. Bez obzira na to, budući razvoj modela bit će usmjeren ka ostvarivanju što objektivnijih odziva. Također, razmotrit će se uključivanje ontoloških opisa ostalih područja iz domene proizvodnih djelatnosti, čime bi se krenulo ka generalizaciji postojećeg spoznajnog modela.

- [1] Grupa autora. (2009, Srpanj) European Robotics Technology Platform. [Online]. [http://www.robotics-platform.eu/cms/index.php?idcatart=119&client=1\(=1?](http://www.robotics-platform.eu/cms/index.php?idcatart=119&client=1(=1?) , 14.04.2013.
- [2] Tomislav Stipančić and Bojan Jerbić, "Self-adaptive Vision System," in *Emerging Trends in Technological Innovation* , Luis M. Camarinha-Matos, Pereira Pedro, and Ribeiro Luis, Eds. Heidelberg: Springer Verlag, 2010, pp. 195-202.
- [3] Ubiquitous computing - Wikipedia. [Online]. http://en.wikipedia.org/wiki/Ubiquitous_computing , 14.04.2013.
- [4] M Weiser, "Hot topics: Ubiquitous computing," *IEEE Computers*, vol. 26, no. 10, pp. 71-72, 1993.
- [5] John Poulakos and Takis Poulakos, *Classical Rhetorical Theory.*: Houghton Mifflin Harcourt, 1999.
- [6] Quantum mechanics - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Quantum_mechanics , 14.04.2013.
- [7] Y.G. Ha, J.C. Sohn, Y.C. Cho, and H. Yoon, "Towards a Ubiquitous Robotic Companion: Design and Implementation of Ubiquitous Robotic Service Framework," *ETRI Journal*, vol. 27, no. 6, pp. 666-676, 2005.
- [8] Systems theory – Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Systems_theory , 14.04.2013.
- [9] M. Baldauf, S. Dustdar, and F. Rosenberg, "A survey on Context – Aware Systems.," *International Journal of Ad Hoc and Ubiquitous Computing*, vol. 2, no. 4, pp. 263-277, 2007.
- [10] H. Kim, Y.J. Cho., and S.R. Oh, "CAMUS - A middleware supporting context-aware services for network-based robots," in *IEEE Workshop on Advanced Robotics and Its Social Impacts*, Nagoya, Japan, 2005, pp. 237-242.
- [11] James Llinas and David Hall, "An Introduction to Multi-Sensor Data Fusion," in *Proceedings of the IEEE*, vol. 85, 1997, pp. 6-20.
- [12] Tomislav Stipančić, Petar Ćurković, and Bojan Jerbić, "Substantial vision application settings analysis," in *CIM*, Zagreb, 2009, pp. 217-220.
- [13] S. Lemaignan, A. Siadat, J.Y. Dantan, and A. Semenenko, "MASON: A Proposal For An Ontology Of Manufacturing Domain," in *Distributed Intelligent Systems: Collective Intelligence and Its Applications, IEEE Workshop*, 2006, pp. 195–200.
- [14] N. Lohse, *Towards an ontology framework for the integrated design of modular assembly systems, PhD Thesis.*: University of Nottingham, 2006.
- [15] Y. Al-Safi and V. Vyatkin, "An Ontology-Based Reconfiguration Agent for Intelligent Mechatronic Systems.," in *Holonic and Multi-Agent Systems for Manufacturing. Lecture Notes in Computer Science*, vol. 4659, 2007, pp. 114-126.
- [16] H., K. Rampersad, *Integrated and Simultaneous Design for Robotic Assembly.*: John Wiley & Sons Ltd, 1994.

- [17] Mittal A., *Bayesian Network Technologies: Applications and Graphical Models.*: IGI Publishing, 2007.
- [18] A. Larik and S. Haider, "Efforts to Blend Ontology with Bayesian Networks: An Overview," in *In Proceedings of 3rd International Conference on Advanced Computer Theory and Engineering*, Chendgu, China, 2010, pp. 598-602.
- [19] P. Mitra, N. Noy, and A. Jaiswal, "OMEN: A Probabilistic Ontology Mapping Tool," in *The Semantic Web - ISWC 2005*, 2005, pp. 537-547.
- [20] Y. Peng, "A Bayesian Network Approach to Ontology Mapping," in *The Semantic Web - ISWC 2005*, 2005, pp. 563-577.
- [21] Z. Ding and Y. Peng, "A probabilistic extension to ontology language OWL," in *System Sciences, Proceedings of the 37th Annual Hawaii International Conference*, Hawauu, 2004, p. 10.
- [22] D. Zhongli, *BayesOWL: A Bayesian Approach to Ontology Mapping.*: PhD thesis, University of Maryland Baltimore County, 2005.
- [23] B. Andrea and T. Franco, "Extending ontology queries with Bayesian network reasoning," in *Intelligent Engineering Systems*, Lucca, Italy, 2009.
- [24] A. Devitt and K. Matusikova, "Constructing Bayesian Networks Automatically using Ontologies," *Applied Ontology*, vol. 1, 2006.
- [25] H. Zheng, B. Kang, and Kim H., "An Ontology-Based Bayesian Network Approach for Representing Uncertainty in Clinical Practice Guidelines," in *ISWC International Workshops, URSW 2005-2007*, 2008, pp. 161-173.
- [26] S. Fenz, A. Tjoa, and M. Hudec, "Ontology-Based Generation of Bayesian Networks," in *Proceedings of the Third International Conference on Complex, Intelligent and Software Intensive Systems*, 2009, pp. 712 - 717.
- [27] P. Costa and K., B. Laskey, "PR-OWL: A Framework for Probabilistic Ontologies," in *Proceedings of the Conference on Formal Ontologies and Information Systems*, 2006, pp. 237-249.
- [28] P. Costa, K., B. Laskey, and K., J. Laskey, "A Bayesian Ontology Language for the Semantic Web," in *Uncertainty Reasoning for the Semantic Web I: ISWC International Workshops*, 2008, pp. 88-107.
- [29] K., B. Laskey, "MEBN: A language for first-order Bayesian knowledge bases," *Artificial Intelligence*, vol. 172, pp. 140-178, 2008.
- [30] S. Thurn, W. Burgard, and D. Fox, *Probabilistic Robotics.*: The MIT Press, 2006.
- [31] Y., C. Go, J., C. Sohn, and Y., J. Cho, "Probabilistic approach to model intelligent robot services," in *Advanced Communication Technology*, 2006, pp. 1221-1224.
- [32] B., K. Daniel, G. McCalla, and R., A. Schwier, "Data mining and modeling social capital in virtual learning communities ," in *Proceedings of the 12th International Conference on Artificial Intelligence in Education* , Amsterdam, 2005, pp. 2000-2008.
- [33] B., K. Daniel, G. McCalla, and R., A. Schwier, "Social capital in virtual learning communities and distributed communities of practice," *The Canadian journal of Learning Technology*, vol. 3, no. 29, pp. 113-139, 2003.
- [34] Semantic Web – W3C. [Online]. <http://www.w3.org/standards/semanticweb/> , 14.04.2013.
- [35] D. Katić et al., "Knowledge-Based Situation Interpretation for Context-Aware

- Augmented Reality in Dental Implant Surgery," in *Lecture Notes in Computer Science*, vol. 6326/2010, 2010, pp. 531-540.
- [36] M. Prcela, *Predstavljanje znanja zasnovano na integraciji ontologija i bayesovih mreža*. Zagreb: Sveučilište u Zagrebu, 2010.
- [37] Web service - Wikipedia, the free encyclopedia. [Online].
http://en.wikipedia.org/wiki/Web_service , 14.04.2013.
- [38] J. M. Mendes, F. Restivo, Leitão P., and A. W. Colombo, "Injecting Service-Oriented into Multi-Agent Systems in Industrial Automation," *Artificial Intelligence and Sift Computing*, vol. 6114/2010, pp. 313-320, 2010.
- [39] J. Puttonen, A. Lobov, M., A. Cavia Soto, and J. L. Martinez Lastra, "A Semantic Web Services-based approach for production systems control," *Advanced Engineering Informatics*, vol. 24, no. 3, pp. 285-299, 2010.
- [40] F. Baader and W. Nutt, *Basic Description Logics (Description Logic Handbook)*, F. Baader et al., Eds.: Cambridge University Press, 2002.
- [41] R.E. Neapolitan, *Learning Bayesian Networks*. Prentice Hall, 2005.
- [42] A. K. Dey and G. D. Abowd, "Toward a better understanding of context and context-awareness," in *Workshop on the What, Who, Where, When and How of Context-Awareness, affiliated with the 2000 ACM Conference on Human Factors in Computer Systems*, 2000.
- [43] OWL Web Ontology Language Current Status – W3C. [Online].
http://www.w3.org/standards/techs/owl#w3c_all/ , 14.04.2013.
- [44] Top Quadrant - TopBraid Suite. [Online].
http://topquadrant.com/products/TB_Suite.html , 14.04.2013.
- [45] T. Lukasiewicz, *Expressive Probabilistic Description Logics. Artificial Intelligence Journal*, vol. 172, pp. 852-883, 2008.
- [46] Bayesian Network – Wikipedia, the free encyclopedia. [Online].
http://en.wikipedia.org/wiki/Bayesian_network , 14.04.2013.
- [47] R. Want, "An introduction to Ubiquitous Computing," in *Ubiquitous Computing Fundamentals*, J. Krumm, Ed.: CRC Press, 2010, pp. 1-33.
- [48] Mark Weiser – Wikipedia, the free encyclopedia. [Online].
http://en.wikipedia.org/wiki/Mark_Weiser , 14.04.2013.
- [49] M. Weiser, "The Computer for the 21st Century," *Scientific American*, pp. 94-104, 1991.
- [50] A.K. Dey and G.D. Abowd, "Towards a Better Understanding of Context and Context-Awareness," Atlanta, GA, USA, 1999.
- [51] A., K. Dey, "Context-Aware Computing," in *Ubiquitous Computing Fundamentals*, J. Krumm, Ed.: CRC Press, 2010.
- [52] H. Clark and S. Brennan, "Grounding in Communication," in *Perspective on Socially Shared Cognition*, L. Resnick, L. Levine, and S. Teasley, Eds. Washinton, DC: APA Books, 1991, pp. 127-149.
- [53] (2009) Pingdom Website Monitoring. [Online].
<http://royal.pingdom.com/2010/01/22/internet-2009-in-numbers/> , 14.04.2013.
- [54] The World Wide Web: Past, Present and Future. [Online].
<http://www.w3.org/People/Berners-Lee/1996/ppf.html> , 14.04.2013.

- [55] T. Berners-Lee, J. Hendler, and O. Lassila, "The Semantic Web," *Scientific American*, pp. 28-37, 2001.
- [56] World Wide Web Consortium (W3C). [Online]. <http://www.w3.org> , 14.04.2013.
- [57] G. Antoniou and Harmelen F., *A Semantic Web Primer, second edition.*: The MIT Press, 2008.
- [58] (2012, kolovoz) Rule Interchange Format – Wikipedia. [Online]. http://en.wikipedia.org/wiki/Rule_Interchange_Format , 14.04.2013.
- [59] I. Horrocks et al. (2004) SWRL: A Semantic Web Rule Language Combining OWL and RuleML. Acknowledged W3C Member Submission. [Online]. <http://www.w3.org/Submission/2004/SUBM-SWRL-20040521/>, 14.04.2013 .
- [60] Aristotel – Wikipedia. [Online]. <http://hr.wikipedia.org/wiki/Aristotel> , 14.04.2013.
- [61] Ontologija – Wikipedia. [Online]. <http://hr.wikipedia.org/wiki/Ontologija>, 14.04.2013 .
- [62] T. Gruber, "Toward Principles for the design of ontologies used for knowledge sharing," *International Journal of Human-Computer Studies*, pp. 907-928, 1994.
- [63] Michael, R. Genesereth and Richard, E., Fikes. (1992) Knowledge Interchange Formal Version 3.0 Reference Manual. [Online]. <http://www-ksl.stanford.edu/knowledge-sharing/kif/>, 14.04.2013 .
- [64] A. Farquhar, Richard, E. Fikes, and J., P. Rice, "The Ontolingua Server: A tool for collaborative ontology construction," *International Journal of Human-Computer Studies*, vol. 46, no. 6, pp. 707-727, 1997.
- [65] Guus Schreiber et al., *Knowledge Engineering and Management-The CommonKADS Methodology*. Cambridge, Massachusetts London, England: The MIT Press, 2000.
- [66] D., B. Lenat and R., V. Guha, *Building Large Knowledge-based Systems: representation and inference in the Cyc project*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., 1989.
- [67] DAML,2006, "The DARPA Agent Markup".[Online]. <http://www.daml.org> , 14.04.2013.
- [68] Y. Sure, S. Staab, and R. Studer, "Ontology Engineering Methodology," in *International Handbooks on Information Systems*, S. Staab and R. Studer, Eds. Berlin: Springer-Verlag, 2009, pp. 135-152.
- [69] Is-a – Wikipedia, the free encyclopedia. [Online]. <http://en.wikipedia.org/wiki/Is-a>, 14.04.2013 .
- [70] F. Luger and G., *Artificial Intelligence: Structures and Strategies for Complex Problem Solving, Fifth Edition* , Addison Wesley, Ed., 2005.
- [71] G. Hellman, *Artificial Intelligence: The Very Idea*. MA: Bradford Books, MIT Press, 1985.
- [72] E. Charniak and D. McDermott, *Introduction to Artificial Intelligence.*: Addison-Wesley Pub.Company, 1985.
- [73] R. Kurzweil, *The Age of Intelligent Machines.*: MIT Press, 1990.
- [74] D. Poole, A. Mackworth, and R. Goebel, *Computational Intelligence: A Logical Approach*. New York: Oxford University Press, 1998.
- [75] Fuzzy logic - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Fuzzy_logic, 14.04.2013 .

- [76] Bayesian inference - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Bayesian_inference, 14.04.2013.
- [77] Principle of maximum entropy - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Principle_of_maximum_entropy, 14.04.2013.
- [78] John McCarthy (computer scientist) - Wikipedia, the free encyclopedia. [Online]. [http://en.wikipedia.org/wiki/John_McCarthy_\(computer_scientist\)](http://en.wikipedia.org/wiki/John_McCarthy_(computer_scientist)), 14.04.2013.
- [79] K. K. Korb. and A. E. B. Nicholson, *Bayesian Artificial Intelligence, Second Edition*.: CRC Press, 2011.
- [80] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach, Third Edition*.: Prentice Hall, 2010.
- [81] A. Kolmogorov, *Grundbegriffe der Wahrscheinlichkeitsrechnung*. Berlin: Springer Verlag, 1993.
- [82] M., J. Druzdzel and L. C. Van der Gaag, "Building probabilistic networks: 'Where do the numbers come from?'," *IEEE Transactions on Knowledge and Data Engineering*, vol. 4, no. 12, pp. 481-486, 2000.
- [83] J. Pearl, *Probabilistic reasoning in intelligent systems: networks of plausible inference*. San Mateo, CA: Morgan Kaufmann, 1988.
- [84] B., K. Daniel, J. Zapata-Rivera, and G., I. McCala, "A Bayesian Belief Network Approach for Modeling Complex Domains," in *In Bayesian Network Technologies: Applications and Graphical Models*, A. Mittal, A. Kassim, and T., T. Hershey, Eds.: IGI Publishing, 2007.
- [85] M., G. Morgan and M. Henrion, *Uncertainty – a guide to deal with uncertainty in quantitative risk and policy analysis*. Cambridge: Cambridge University Press, 1990.
- [86] M. Wooldridge, *An Introduction to MultiAgent Systems*. Chichester: John Wiley & Sons, 2009.
- [87] P. Ćurković, *Evolutivni algoritam za upravljanje višegentskim robotskim sustavom. Doktorski rad*. Zagreb: Sveučilište u Zagrebu, 2010.
- [88] T. Stipančić, B. Jerbić, and P. Curkovic, "A Bayesian Approach to Robot Group Control," *Computer Technology and Application*, vol. 2, no. 9, pp. 716-723, 2011.
- [89] T. Stipančić, B. Jerbić, and P. Ćurković, "Probabilistic Approach to Robot Group Control," *Advanced Materials Research*, vol. 317-319, pp. 742-749, 2011.
- [90] T. Stipančić, B. Jerbić, and P. Curkovic, "Bayesian Approach to Robot Group Control," in *Electrical Engineering and Intelligent Systems*, Sio-long Ao and Len Gelman, Eds. New York, USA: Springer, 2012, vol. 130, pp. 109-119.
- [91] T. Stipančić, B. Jerbić, and P. Curkovic, "A Robot Group Control Based on Bayesian Reasoning," in *Lecture Notes in Engineering and Computer Science*, vol. 2191, Hong Kong, 2011, pp. 1056-1060.
- [92] T. Stipančić, B. Jerbić, and P. Curkovic, "Probabilistic Approach to Robot Group Control," in *Proceedings of the 2011 International Conference on Advanced Design and Manufacturing Engineering*, Guangzhou, China, 2011.
- [93] Tomislav Stipančić, Bojan Jerbić, and Petar Ćurković, "Context-Aware System Applied in Industrial Assembly Environment," *International Journal of Advanced Robotic Systems*, vol. 9, no. 234, 2012.
- [94] Tomislav Stipančić, Petar Ćurković, and Jerbić Bojan, "Robust autonomous

- assembly in environment with relatively high level of uncertainty," in *10th International Conference on The Modern Information Technology in the Innovation Processes of the Industrial Enterprises*, Pilsen, Češka, 2008, pp. 193-198.
- [95] Smart environment – Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Smart_environment , 14.04.2013.
- [96] DeviceNet – Wikipedia, the free encyclopedia. [Online]. <http://en.wikipedia.org/wiki/DeviceNet>, 14.04.2013.
- [97] D. Cohen and L. Prusak, *In good company: How social capital makes organizations work*. MA: Harvard Business School Press, 2001.
- [98] R. Putnam, *Bowling alone: The collapse and revival of American community.*: New York Schuster, 2000.
- [99] A. Danis L., C., T. Miller, and Y. Jung, "Fostering social interaction in online spaces," in *Proceedings of the Eight IFIP TC.13 Conference on Human-Computer Interaction (INTERACT'01)*, Amsterdam, 2001, pp. 59-66.
- [100] Open world assumption - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Open_world_assumption, 14.04.2013.
- [101] B., K. Daniel, J., D. Zapata-Rivera, and G., I. McCalla, "A Bayesian computational model of social capital in virtual communities," in *Communities and technologies*, London, pp. 287-305.
- [102] Kvalitativno istraživanje - Wikipedija. [Online]. http://hr.wikipedia.org/wiki/Kvalitativno_istraživanje, 14.04.2013.
- [103] N. Pennington and R. Hastie, "Explanation-based decision-making: Effects on memory structure on judgement," *Journal of Experimental Psychology: Learning, Memory and Cognition*, vol. 3, no. 14, pp. 521-533, 1988.
- [104] M. Druzdzel and J., S. Henri, "Relevance in probabilistic models: "Backyards" in a "small world"," in *Working notes of the AAAI-1994 Fall Symposium Series*, New Orleans, LA, pp. 60 – 63.
- [105] S., H. Chen, "Good practice in Bayesian network modeling," *Environmental Modelling & Software*, vol. 37, November 2012.
- [106] A., J. Jakeman, R., A. Letcher, and J. P. Norton, "Ten iterative steps in development and evaluation of environmental models," *Environmental Modelling & Software* , no. 21, pp. 602-614., 2006.
- [107] Information Theory - Wikipedia, the free encyclopedia. [Online]. http://en.wikipedia.org/wiki/Information_theory, 14.04.2013.
- [108] Norsys Software Corp. - Bayes Met Software. [Online]. <https://www.norsys.com> , 14.04.2013.
- [109] Genie & Smile. [Online]. <http://genie.sis.pitt.edu>, 14.04.2013.

OBRAZAC PONAŠANJA *BPI*

```
a      owl:Class ;
rdfs:subClassOf owl:BehavioralPattern1 ;
rdfs:subClassOf
  [ a      owl:Class ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC11
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostSP11
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostCS11
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "assembly"^^xsd:string ,
"part"^^xsd:string , "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS11
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS12
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC12
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostOB11
        ]
      ] ;
rdfs:subClassOf
  [ a      owl:Class ;
    owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostSP11
      ] ;
      owl:isActivatedBy
```

```

        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostOB11
        ] ;
    owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC11
        ] ;
    owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS12
        ] ;
    owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC12
        ] ;
    owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS11
        ] ;
    owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostCS11
        ]
    ] .

```

OBRAZAC PONAŠANJA BP2

```

owl:BP12
    a      owl:Class ;
    rdfs:subClassOf owl:BehavioralPattern1 ;
    rdfs:subClassOf
        [ a      owl:Class ;
          owl:isActivatedBy
            [ a      owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostCS11
            ] ;
          owl:isActivatedBy
            [ a      owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostSP11
            ] ;
          owl:isActivatedBy
            [ a      owl:Restriction ;
              owl:hasValue "false"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostOB11
            ] ;
          owl:isActivatedBy
            [ a      owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostTC12
            ] ;
        ]

```



```

        owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostTC11
            ] ;
        owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "false"^^xsd:string ;
              owl:onProperty owl:imaVrijednostVS11
            ] ;
        owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "false"^^xsd:string ;
              owl:onProperty owl:imaVrijednostVS12
            ]
    ] ;
    rdfs:subClassOf
        [ a owl:Class ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "false"^^xsd:string ;
              owl:onProperty owl:imaVrijednostVS12
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostCS11
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "assembly"^^xsd:string ,
"product"^^xsd:string , "part"^^xsd:string , "false"^^xsd:string ;
              owl:onProperty owl:imaVrijednostVS11
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostTC11
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostOB11
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostTC12
            ] ;
          owl:isActivatedBy
            [ a owl:Restriction ;
              owl:hasValue "true"^^xsd:boolean ;
              owl:onProperty owl:imaVrijednostSP11
            ]
        ] ;
    rdfs:subClassOf

```

```

[ a      owl:Class ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostSP11
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "false"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostOB11
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostTC11
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostTC12
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "false"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostCS11
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "false"^^xsd:string ;
      owl:onProperty owl:imaVrijednostVS12
    ] ;
  owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "assembly"^^xsd:string ,
"part"^^xsd:string , "false"^^xsd:string ;
      owl:onProperty owl:imaVrijednostVS11
    ]
] .

```

OBRAZAC PONAŠANJA BP3

```

owl:BP13
  a      owl:Class ;
  rdfs:subClassOf owl:BehavioralPattern1 ;
  rdfs:subClassOf
    [ a      owl:Class ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostOB11
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC12
        ] ;
      owl:isActivatedBy
        [ a      owl:Restriction ;

```

```
        owl:hasValue "false"^^xsd:string ;
        owl:onProperty owl:imaVrijednostVS12
    ] ;
    owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "false"^^xsd:string ;
      owl:onProperty owl:imaVrijednostVS11
    ] ;
    owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostTC11
    ] ;
    owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostCS11
    ] ;
    owl:isActivatedBy
    [ a      owl:Restriction ;
      owl:hasValue "true"^^xsd:boolean ;
      owl:onProperty owl:imaVrijednostSP11
    ]
    ] ;
    rdfs:subClassOf
    [ a      owl:Class ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostTC12
      ] ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostOB11
      ] ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostTC11
      ] ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ;
        owl:onProperty owl:imaVrijednostSP11
      ] ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "false"^^xsd:string ;
        owl:onProperty owl:imaVrijednostVS12
      ] ;
      owl:isActivatedBy
      [ a      owl:Restriction ;
        owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;

```

```

        owl:onProperty owl:imaVrijednostCS11
    ] ;
    owl:isActivatedBy
    [ a owl:Restriction ;
      owl:hasValue "product"^^xsd:string ;
      owl:onProperty owl:imaVrijednostVS11
    ]
] .

```

OBRAZAC PONAŠANJA *BP4*

```

owl:BP14
  a owl:Class ;
  rdfs:subClassOf owl:BehavioralPattern1 ;
  rdfs:subClassOf
    [ a owl:Class ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostCS11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS12
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostOB11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostSP11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC12
        ]
    ] .

```

OBRAZAC PONAŠANJA BP5

```
owl:BP15
  a owl:Class ;
  rdfs:subClassOf owl:BehavioralPattern1 ;
  rdfs:subClassOf
    [ a owl:Class ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "false"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS12
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostCS11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostOB11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "assembly"^^xsd:string ,
"part"^^xsd:string ;
          owl:onProperty owl:imaVrijednostVS11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC12
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostSP11
        ] ;
      owl:isActivatedBy
        [ a owl:Restriction ;
          owl:hasValue "true"^^xsd:boolean ,
"false"^^xsd:boolean ;
          owl:onProperty owl:imaVrijednostTC11
        ]
    ] .
```

PRILOG B. Izračun težinskih faktora varijabli

Tablica PB-1. *Jedan roditelj - varijabla Interaction.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 1 = 0.48$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 1 = 0.3$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 1 = 0.1$

Tablica PB-2. *Dva roditelja - varijabla Shared Understanding.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-3. *Dva roditelja - varijabla Origin Awareness.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-4. *Dva roditelja - varijabla Competence Awareness.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-5. *Dva roditelja - varijabla Capability Awareness.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-6. *Četiri roditelja - varijabla Trust.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 4 = 0.12$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 4 = 0.075$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 4 = 0.025$

Tablica PB-7. *Pet roditelja - varijabla Social Capital.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 5 = 0.096$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 5 = 0.06$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 5 = 0.02$

Tablica PB-8. *Tri roditelja - varijabla Self Assessment.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 3 = 0.16$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 3 = 0.1$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 3 = 0.033$

Tablica PB-9. *Dva roditelja - varijabla BP1.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-10. *Dva roditelja - varijabla BP2.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-11. *Dva roditelja - varijabla BP3.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-12. *Dva roditelja - varijabla BP4.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

Tablica PB-13. *Dva roditelja - varijabla BP5.*

Stupanj utjecaja	Prag	Težinski faktor
<i>Strong</i>	$1-\alpha = 1-0.02 = 0.98$	$(0.98 - 0.5) / 2 = 0.24$
<i>Medium</i>	0.8	$(0.8 - 0.5) / 2 = 0.15$
<i>Weak</i>	0.6	$(0.6 - 0.5) / 2 = 0.05$

PRILOG C. Izračun vrijednosti uvjetnih vjerojatnosti

Tablica PC-1. Čvor *Attitude*.

	<i>Positive</i>	<i>Negative</i>
<i>Attitude</i>	0.7	0.3

Izračun vrijednosti – varijabla *Interactions*:

- $P(\text{Interactions} = \text{positive} \mid \text{Attitudes} = \text{positive}) = 0.5 + 0.3 = 0.8,$
- $P(\text{Interactions} = \text{negative} \mid \text{Attitudes} = \text{positive}) = 1 - 0.8 = 0.2,$
- $P(\text{Interactions} = \text{positive} \mid \text{Attitudes} = \text{negative}) = 0.5 + 0.3 = 0.8,$
- $P(\text{Interactions} = \text{negative} \mid \text{Attitudes} = \text{negative}) = 1 - 0.8 = 0.2.$

Tablica PC-2. CPT - čvor *Interactions*.

	<i>Attitude</i>	<i>Positive</i>	<i>Negative</i>
<i>Interactions</i>	<i>Positive</i>	0.8	0.8
	<i>Negative</i>	0.2	0.2

Izračun vrijednosti – varijabla *Shared Understanding*:

- $(\text{SharedUnderstanding} = \text{high} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 + 0.24 = 0.79,$
- $P(\text{SharedUnderstanding} = \text{low} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 1 - 0.79 = 0.21,$
- $P(\text{SharedUnderstanding} = \text{high} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 0.5 + 0.05 = 0.55,$
- $P(\text{SharedUnderstanding} = \text{low} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 1 - 0.55 = 0.45,$
- $P(\text{SharedUnderstanding} = \text{high} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 0.5 + 0.24 = 0.74,$
- $P(\text{SharedUnderstanding} = \text{low} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 1 - 0.74 = 0.26,$
- $P(\text{OriginAwareness} = \text{high} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.21$

- $P(\text{OriginAwareness} = \text{low} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 1 - 0.21 = 0.79.$

Tablica PC-3. CPT - čvor Shared Understanding.

	<i>Attitude</i>	<i>positive</i>		<i>negative</i>		
		<i>Interactions</i>	<i>positive</i>	<i>negative</i>	<i>positive</i>	<i>negative</i>
Shared Understanding	High		0.79	0.55	0.74	0.21
	Low		0.21	0.45	0.26	0.79

Izračun vrijednosti – varijabla *Origin Awareness*:

- $P(\text{OriginAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 + 0.15 = 0.7,$
- $P(\text{OriginAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 1 - 0.7 = 0.3,$
- $P(\text{OriginAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 0.5 + 0.05 = 0.55,$
- $P(\text{OriginAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 1 - 0.55 = 0.45,$
- $P(\text{OriginAwareness} = \text{present} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 = 0.65,$
- $P(\text{OriginAwareness} = \text{absent} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 1 - 0.65 = 0.35,$
- $P(\text{OriginAwareness} = \text{present} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.3,$
- $P(\text{OriginAwareness} = \text{absent} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 1 - 0.3 = 0.7.$

Tablica PC-4. CPT - čvor Origin Awareness.

	<i>Attitude</i>	<i>positive</i>		<i>negative</i>		
		<i>Interactions</i>	<i>positive</i>	<i>negative</i>	<i>positive</i>	<i>negative</i>
Origin Awareness	Present		0.7	0.55	0.65	0.3
	Absent		0.3	0.45	0.35	0.7

Izračun vrijednosti – varijabla *Competence Awareness*:

- $P(\text{CompetenceAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.15 + 0.15 = 0.8,$
- $P(\text{CompetenceAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 1 - 0.8 = 0.2,$
- $P(\text{CompetenceAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 0.5 + 0.15 = 0.65,$
- $P(\text{CompetenceAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 1 - 0.65 = 0.35,$
- $P(\text{CompetenceAwareness} = \text{present} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 0.5 + 0.15 = 0.65,$
- $P(\text{CompetenceAwareness} = \text{absent} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 1 - 0.65 = 0.35,$
- $P(\text{CompetenceAwareness} = \text{present} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.2,$
- $P(\text{CompetenceAwareness} = \text{absent} \mid \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 1 - 0.2 = 0.8.$

Tablica PC-5. CPT – čvor *Competence Awareness*.

	<i>Attitude</i>	<i>positive</i>		<i>negative</i>		
		<i>Interactions</i>	<i>positive</i>	<i>negative</i>	<i>positive</i>	<i>negative</i>
Competence Awareness	<i>Present</i>		0.8	0.65	0.65	0.2
	<i>Absent</i>		0.2	0.35	0.35	0.8

Izračun vrijednosti – varijabla *Capability Awareness*:

- $P(\text{CapabilityAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 0.5 + 0.15 + 0.05 = 0.7,$
- $P(\text{CapabilityAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{positive}) = 1 - 0.7 = 0.3,$
- $P(\text{CapabilityAwareness} = \text{present} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 0.5 + 0.15 = 0.65,$
- $P(\text{CapabilityAwareness} = \text{absent} \mid \text{Attitudes} = \text{positive} \& \text{Interactions} = \text{negative}) = 1 - 0.65 = 0.35,$

- $P(\text{CapabilityAwareness} = \text{present} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 0.5 + 0.05 = 0.55,$
- $P(\text{CapabilityAwareness} = \text{absent} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{positive}) = 1 - 0.55 = 0.45,$
- $P(\text{CapabilityAwareness} = \text{present} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 0.3,$
- $P(\text{CapabilityAwareness} = \text{absent} / \text{Attitudes} = \text{negative} \& \text{Interactions} = \text{negative}) = 1 - 0.3 = 0.7.$

Tablica PC-6. CPT - čvor *Capability Awareness*.

	<i>Attitude</i>	<i>positive</i>		<i>negative</i>		
		<i>Interactions</i>	<i>positive</i>	<i>negative</i>	<i>positive</i>	<i>negative</i>
Origin Awareness	<i>Present</i>		0.7	0.65	0.55	0.3
	<i>Absent</i>		0.3	0.35	0.45	0.7

Izračun vrijednosti – varijabla *Trust*:

- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 + 0.12 + 0.12 = 0.98,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.98 = 0.02,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 + 0.12 = 0.86,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.86 = 0.14,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 + 0.12 = 0.86,$

- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.86 = 0.14,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 + 0.12 = 0.86,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.86 = 0.14,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 + 0.12 + 0.12 = 0.86,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.86 = 0.14,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 + 0.12 = 0.74,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.74 = 0.26,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 + 0.12 = 0.74,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.74 = 0.26,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 = 0.74,$

- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.74 = 0.26,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 + 0.12 = 0.74,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.74 = 0.26,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 = 0.74,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.74 = 0.26,$
- $P(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.12 + 0.12 = 0.74,$
- $P(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.74 = 0.26,$
- $(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 = 0.62,$
- $(\text{Trust} = \text{low} / \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.62 = 0.38,$
- $(\text{Trust} = \text{high} / \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.12 = 0.62,$

- ($Trust = low / SharedUnderstanding = low \& OriginAwareness = present \& CompetenceAwareness = absent \& CapabilityAwareness = absent$) = $1 - 0.62 = 0.38$,
- ($Trust = high / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = present \& CapabilityAwareness = absent$) = $0.5 + 0.12 = 0.62$,
- ($Trust = low / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = present \& CapabilityAwareness = absent$) = $1 - 0.62 = 0.38$,
- ($Trust = high / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = absent \& CapabilityAwareness = present$) = $0.5 + 0.12 = 0.62$,
- ($Trust = low / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = absent \& CapabilityAwareness = present$) = $1 - 0.62 = 0.38$,
- ($Trust = high / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = absent \& CapabilityAwareness = absent$) = 0.02 ,
- ($Trust = low / SharedUnderstanding = low \& OriginAwareness = absent \& CompetenceAwareness = absent \& CapabilityAwareness = absent$) = 0.98 .

Izračun vrijednosti – varijabla *Social Capital*:

- $P(SocialCapital = high / Trust = high \& SharedUnderstanding = high \& OriginAwareness = present \& CompetenceAwareness = present \& CapabilityAwareness = present)$ = $0.5 + 0.096 + 0.096 + 0.06 + 0.096 + 0.096 = 0.944$,
- $P(SocialCapital = low / Trust = high \& SharedUnderstanding = high \& OriginAwareness = present \& CompetenceAwareness = present \& CapabilityAwareness = present)$ = $1 - 0.944 = 0.056$,
- $P(SocialCapital = high / Trust = low \& SharedUnderstanding = high \& OriginAwareness = present \& CompetenceAwareness = present)$ =

- $P(\text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.06 + 0.096 + 0.096 = 0.848,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.848 = 0.152,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.06 + 0.096 + 0.096 = 0.848,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.848 = 0.152,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 + 0.096 + 0.096 = 0.884,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.884 = 0.116,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 + 0.06 + 0.096 = 0.848,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.848 = 0.152,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 + 0.06 + 0.096 = 0.848,$

- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.848 = 0.152,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.06 + 0.096 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.752 = 0.248,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 + 0.096 = 0.788,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.788 = 0.212,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.06 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.752 = 0.248,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.06 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.752 = 0.248,$

- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.06 + 0.096 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.752 = 0.248,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 + 0.096 = 0.788,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.788 = 0.212,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 + 0.06 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.752 = 0.248,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.06 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.752 = 0.248,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} =$

- $P(\text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.06 + 0.096 = 0.752,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.752 = 0.248,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 + 0.096 = 0.788,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.788 = 0.212,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 + 0.06 = 0.752,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.752 = 0.248,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.06 + 0.096 = 0.656,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.656 = 0.344,$
 - $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 = 0.692,$
 - $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.692 = 0.308,$

- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.06 = 0.656,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.656 = 0.344,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.06 + 0.096 = 0.656,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.656 = 0.344,$

- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 + 0.06 = 0.656,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.656 = 0.344,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 + 0.096 = 0.692,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.692 = 0.308,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.096 = 0.596,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.596 = 0.404,$

- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 = 0.596$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.596 = 0.404,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.06 = 0.56,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.56 = 0.44,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 = 0.596,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{high} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.596 = 0.404,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.096 = 0.596,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{high} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.596 = 0.404,$
- $P(\text{SocialCapital} = \text{high} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.056,$
- $P(\text{SocialCapital} = \text{low} / \text{Trust} = \text{low} \& \text{SharedUnderstanding} = \text{low} \& \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.944.$

Tablica PC-7. CPT - čvor Trust.

<i>Shared Understanding</i>		<i>high</i>								<i>low</i>							
		<i>present</i>				<i>absent</i>				<i>present</i>				<i>absent</i>			
<i>Trust</i>	<i>Origin Awareness</i>	<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>	
	<i>Competence Awareness</i>	<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>	
	<i>Capability Awareness</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>
	<i>High</i>	0.98	0.86	0.86	0.74	0.86	0.74	0.74	0.62	0.86	0.74	0.74	0.62	0.74	0.62	0.62	0.02
	<i>Low</i>	0.02	0.14	0.14	0.26	0.14	0.26	0.26	0.38	0.14	0.26	0.26	0.38	0.26	0.38	0.38	0.98

Tablica PC-8. CPT - čvor Social Capital.

<i>TR</i>		<i>high</i>								<i>low</i>							
<i>SU</i>		<i>high</i>				<i>low</i>				<i>high</i>				<i>low</i>			
<i>SC</i>	<i>OA</i>	<i>present</i>				<i>absent</i>				<i>present</i>				<i>absent</i>			
	<i>CA</i>	<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>	
	<i>CP</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>
	<i>H</i>	0.944	0.848	0.848	0.752	0.884	0.788	0.788	0.692	0.848	0.752	0.752	0.656	0.752	0.692	0.692	0.596
	<i>L</i>	0.056	0.152	0.152	0.248	0.116	0.212	0.212	0.308	0.152	0.248	0.248	0.344	0.248	0.308	0.308	0.404

<i>TR</i>		<i>high</i>								<i>low</i>							
<i>SU</i>		<i>high</i>				<i>low</i>				<i>high</i>				<i>low</i>			
<i>SC</i>	<i>OA</i>	<i>present</i>				<i>absent</i>				<i>present</i>				<i>absent</i>			
	<i>CA</i>	<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>	
	<i>CP</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>
	<i>H</i>	0.848	0.752	0.752	0.656	0.788	0.692	0.692	0.596	0.752	0.656	0.656	0.56	0.752	0.596	0.596	0.056
	<i>L</i>	0.152	0.248	0.248	0.344	0.212	0.308	0.308	0.404	0.248	0.344	0.344	0.44	0.248	0.404	0.404	0.944

SC – Social Capital; TR – Trust; SU – Shared Understanding; OA – Origin Awareness; CA – Competence Awareness; CP – Capability Awareness; H – High; L – Low

Izračun vrijednosti – varijabla *Self Assessment*:

- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.1 + 0.1 + 0.16 = 0.86,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.86 = 0.14,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.1 + 0.1 = 0.7,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.7 = 0.3,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.1 + 0.16 = 0.76,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.76 = 0.24,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.1 + 0.16 = 0.76,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.76 = 0.24,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.1 = 0.6,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{present} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.6 = 0.4,$

- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 0.5 + 0.1 = 0.6,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{present} \& \text{CapabilityAwareness} = \text{absent}) = 1 - 0.6 = 0.4,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 0.5 + 0.16 = 0.66,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{present}) = 1 - 0.66 = 0.34,$
- $P(\text{SelfAssessment} = \text{competent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.14,$
- $P(\text{SelfAssessment} = \text{incompetent} / \text{OriginAwareness} = \text{absent} \& \text{CompetenceAwareness} = \text{absent} \& \text{CapabilityAwareness} = \text{absent}) = 0.86.$

Tablica PC-9. CPT - čvor Self Assessment.

		<i>Origin Awareness</i>				<i>present</i>				<i>absent</i>			
		<i>Competence Awareness</i>		<i>Capability Awareness</i>		<i>present</i>		<i>absent</i>		<i>present</i>		<i>absent</i>	
<i>Self Assessment</i>		<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>	<i>present</i>	<i>absent</i>
		<i>Competent</i>	0.86	0.7	0.76	0.6	0.76	0.6	0.66	0.14			
	<i>Incompetent</i>	0.14	0.3	0.24	0.4	0.24	0.4	0.34	0.86				

Izračun vrijednosti – varijabla *BP1*:

- $(BP1 = \text{True} / \text{SocialCapital} = \text{high} \& \text{SelfAssessment} = \text{competent}) = 0.5 + 0.05 + 0.24 = 0.79,$
- $P(BP1 = \text{False} / \text{SocialCapital} = \text{high} \& \text{SelfAssessment} = \text{competent}) = 1 - 0.79 = 0.21,$
- $P(BP1 = \text{True} / \text{SocialCapital} = \text{high} \& \text{SelfAssessment} = \text{incompetent}) = 0.5 + 0.05 = 0.55,$

- $P(BP1 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.45,$
- $P(BP1 = 1 / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP1 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP1 = 1 / SocialCapital = low \& SelfAssessment = incompetent) = 0.21,$
- $P(BP1 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.79.$

Tablica PC-10. CPT čvor BP1.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
BP1	<i>True</i>	0.79	0.55	0.74	0.21	
	<i>False</i>	0.21	0.45	0.26	0.79	

Izračun vrijednosti – varijabla BP2:

- $(BP2 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.05 = 0.79,$
- $P(BP2 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.79 = 0.21,$
- $P(BP2 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP2 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP2 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.05 = 0.55,$
- $P(BP2 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.55 = 0.45,$
- $P(BP2 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.21,$
- $P(BP2 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.79$

Tablica PC-11. CPT - čvor BP2.

	Social Capital		high		low	
	Self Assessment	competent	incompetent	competent	incompetent	
		BP2	True	0.79	0.74	0.55
	False	0.21	0.26	0.45	0.79	

Izračun vrijednosti – varijabla BP3:

- $(BP3 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP3 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP3 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP3 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP3 = True \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP3 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP3 = True \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP3 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-12. CPT - čvor BP3.

	Social Capital		high		low	
	Self Assessment	competent	incompetent	competent	incompetent	
		BP3	True	0.98	0.74	0.74
	False	0.02	0.26	0.26	0.98	

Izračun vrijednosti – varijabla BP4:

- $(BP4 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP4 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$

- $P(BP4 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP4 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP4 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP4 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP4 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP4 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-13. CPT - čvor BP4.

<i>BP4</i>	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
	<i>True</i>	0.98	0.74	0.74	0.02	
	<i>False</i>	0.02	0.26	0.26	0.98	

Izračun vrijednosti – varijabla BP5:

- $(BP5 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP5 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP5 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP5 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP5 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP5 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$

- $P(BP5 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP5 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-14. CPT - čvor BP5.

<i>BP5</i>	<i>Social Capital</i>	<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>
	<i>True</i>	0.98	0.74	0.74	0.02
<i>False</i>	0.02	0.26	0.26	0.98	

Izračun vrijednosti – varijabla *BP1*:

- $(BP1 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.15 + 0.24 = 0.89,$
- $P(BP1 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.11,$
- $P(BP1 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.15 = 0.65,$
- $P(BP1 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.65 = 0.35,$
- $P(BP1 = 1 / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP1 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP1 = 1 / SocialCapital = low \& SelfAssessment = incompetent) = 0.11,$
- $P(BP1 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.89.$

Tablica PC-15. CPT - čvor BP1.

<i>BP1</i>	<i>Social Capital</i>	<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>
	<i>True</i>	0.89	0.65	0.74	0.11
<i>False</i>	0.11	0.35	0.26	0.89	

Izračun vrijednosti – varijabla *BP2*:

- $(BP2 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP2 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP2 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP2 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP2 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP2 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP2 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP2 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-16. CPT - čvor *BP2*.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
<i>BP2</i>	<i>True</i>	0.98	0.74	0.74	0.02	
	<i>False</i>	0.02	0.26	0.26	0.98	

Izračun vrijednosti – varijabla *BP3*:

- $(BP3 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP3 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP3 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP3 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.74 = 0.26,$

- $P(BP3 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP3 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP3 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP3 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-17. CPT - čvor BP3.

<i>BP3</i>	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
		<i>True</i>	0.98	0.74	0.74	0.02
<i>False</i>	0.02	0.26	0.26	0.98		

Izračun vrijednosti – varijabla *BP4*:

- $(BP4 = True / SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP4 = False / SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP4 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP4 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP4 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP4 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP4 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$

- $P(BP4 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-18. CPT - čvor BP4.

<i>BP4</i>	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
		<i>True</i>	0.98	0.74	0.74	0.02
<i>False</i>	0.02	0.26	0.26	0.98		

Izračun vrijednosti – varijabla *BP5*:

- $(BP5 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.24 = 0.98,$
- $P(BP5 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.02,$
- $P(BP5 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74,$
- $P(BP5 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP5 = True \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP5 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP5 = True \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.02,$
- $P(BP5 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.98.$

Tablica PC-19. CPT - čvor BP5.

<i>BP5</i>	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
		<i>True</i>	0.98	0.74	0.74	0.02
<i>False</i>	0.02	0.26	0.26	0.98		

PRILOG D. Korigirane vrijednosti uvjetnih vjerojatnosti

Izračun vrijednosti – varijabla *BP1*:

- $P(BP1 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.05 + 0.24 = 0.79$,
- $P(BP1 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.79 = 0.21$,
- $P(BP1 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.05 = 0.55$,
- $P(BP1 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.45$,
- $P(BP1 = 1 \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74$,
- $P(BP1 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26$,
- $P(BP1 = 1 \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.21$,
- $P(BP1 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.21$.

Tablica PD-1. CPT - čvor *BP1*.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
<i>BP1</i>	<i>True</i>	0.79	0.55	0.74	0.21	
	<i>False</i>	0.21	0.45	0.26	0.79	

Izračun vrijednosti – varijabla *BP2*:

- $P(BP2 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.05 = 0.79$,
- $P(BP2 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.21$,
- $P(BP2 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.74$,

- $P(BP2 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.55 = 0.26,$
- $P(BP2 = True \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.05 = 0.55,$
- $P(BP2 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.55 = 0.45,$
- $P(BP2 = True \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.21,$
- $P(BP2 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.79.$

Tablica PD-2. CPT - BP2.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
<i>BP2</i>	<i>True</i>	0.79	0.74	0.55	0.21	
	<i>False</i>	0.21	0.26	0.45	0.79	

Izračun vrijednosti – varijabla BP3:

- $(BP3 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.24 + 0.15 = 0.8,$
- $P(BP3 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.8 = 0.2,$
- $P(BP3 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.24 = 0.65,$
- $P(BP3 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.74 = 0.35,$
- $P(BP3 = True \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.15 = 0.65,$
- $P(BP3 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.65 = 0.35,$
- $P(BP3 = True \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.2,$
- $P(BP3 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.8.$

Tablica PD-3. CPT - čvor BP3.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
		<i>True</i>	0.8	0.65	0.65	0.2
<i>BP3</i>	<i>False</i>	0.2	0.35	0.35	0.8	

Izračun vrijednosti – varijabla BP4:

- $P(BP4 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.15 + 0.24 = 0.89,$
- $P(BP4 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.11,$
- $P(BP4 = True \mid SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.15 = 0.65,$
- $P(BP4 = False \mid SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.65 = 0.35,$
- $P(BP4 = True \mid SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP4 = False \mid SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP4 = True \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.11,$
- $P(BP4 = False \mid SocialCapital = low \& SelfAssessment = incompetent) = 0.89.$

Tablica PD-4. CPT - čvor BP4.

	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>	<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>	
		<i>True</i>	0.89	0.65	0.74	0.11
<i>BP4</i>	<i>False</i>	0.11	0.35	0.26	0.89	

Izračun vrijednosti – varijabla BP5:

- $(BP5 = True \mid SocialCapital = high \& SelfAssessment = competent) = 0.5 + 0.15 + 0.24 = 0.89,$
- $P(BP5 = False \mid SocialCapital = high \& SelfAssessment = competent) = 1 - 0.89 = 0.11,$

- $P(BP5 = True / SocialCapital = high \& SelfAssessment = incompetent) = 0.5 + 0.15 = 0.65$
- $P(BP5 = False / SocialCapital = high \& SelfAssessment = incompetent) = 1 - 0.65 = 0.35,$
- $P(BP5 = True / SocialCapital = low \& SelfAssessment = competent) = 0.5 + 0.24 = 0.74,$
- $P(BP5 = False / SocialCapital = low \& SelfAssessment = competent) = 1 - 0.74 = 0.26,$
- $P(BP5 = True / SocialCapital = low \& SelfAssessment = incompetent) = 0.11,$
- $P(BP5 = False / SocialCapital = low \& SelfAssessment = incompetent) = 0.89.$

Tablica PD-5. CPT - čvor BP5.

<i>BP5</i>	<i>Social Capital</i>		<i>high</i>		<i>low</i>	
	<i>Self Assessment</i>		<i>competent</i>	<i>incompetent</i>	<i>competent</i>	<i>incompetent</i>
			<i>True</i>	<i>False</i>	<i>True</i>	<i>False</i>
	<i>True</i>		0.89	0.65	0.74	0.11
	<i>False</i>		0.11	0.35	0.26	0.89

Vrijednosti uvjetnih vjerojatnosti na ostalim čvorovima su ostale nepromijenjene.

Životopis

Ime i prezime:	Tomislav Stipančić
E-mail:	tomislav.stipancic@fsb.hr
Datum rođenja:	09.07.1976.
Mjesto rođenja:	Zagreb, Croatia.
Školovanje:	<u>2007. – 2013.</u> , poslijediplomski studij strojarstva, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, <u>1995. – 2006.</u> , dodiplomski studij strojarstva, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, <u>1991. – 1995.</u> , srednja tehnička škola, Zagreb, <u>1983. – 1992.</u> , osnovna škola, Zagreb.
Dodatna edukacija	<u>2005. – 2006.</u> , E – learning akademija: E – tutoring program (ELA, druga generacija, Tutoring http://www.carnet.hr/education/e-learning_academy) , <u>2002.- 2003.</u> , program za edukaciju <i>CARNetovih</i> predavača (Training the Trainers).
Znanje jezika:	Govori i piše engleski jezik.
Sudjelovao na znanstveno-istraživačkim projektima:	<u>2011. – danas</u> , istraživač, “Primjena robota u neurokirurgiji”, projekt financiran od <i>BICRO-a</i> , Poslovno-inovacijske agencije RH, glavni istraživač prof. dr. sc. Bojan Jerbić. <u>2009. – 2011.</u> , istraživač, “Improving GRAsping Movements by Predictions based on Observation”, <i>UKF</i> projekt financiran od Ministarstva znanosti edukacije i sporta <i>RH</i> , glavni istraživač prof. dr. sc. Danica Kragić. <u>2008. – istraživač</u> , tehnološki projekt “Automatska montaža dvoručnim robotom”, TP-08/0120-53, projekt financiran od Hrvatskog instituta za tehnologiju, glavni istraživač prof. dr. sc. Bojan Jerbić. <u>2007. – istraživač</u> , “Autonomna višeagentna automatska montaža”, znanstveni projekt broj 120-1201948-1941, financiran od strane Ministarstva znanosti, edukacije i sporta <i>RH</i> , glavni istraživač prof. dr. sc. Bojan Jerbić.
Pozicije:	<u>2010. – 2012.</u> , voditelj Laboratorija za projektiranje izradbenih i montažnih sustava, Fakultet strojarstva i brodogradnje, Zagreb, <u>2007. – danas</u> , znanstveni novak, Fakultet strojarstva i brodogradnje, Zagreb, <u>2002. – danas</u> , <i>CARNet</i> (Hrvatska akademska istraživačka mreža), E-mentor ekspert, predavač.

Znanstveno usavršavanje	2012., travanj – svibanj, istraživački posjet <i>URJC</i> Madrid, Kraljevina Španjolska. 2009., lipanj – srpanj i 2011., siječanj – veljača, istraživački posjet <i>KTH</i> Stockholm, Kraljevina Švedska.
Nagrade:	2009., Comenius-EduMedia-Awards, E-tečaj za e-mentore, 2009., Zlatno Teslino odličje, Institut Ruđer Bošković i časopis <i>Vidi</i> u konkurenciji akademskih ustanova, projekt dvoručnog robotskog sustava. 2009., Povelja za najbolji e-kolegij na Fakultetu strojarstva i brodogradnje, 2006., Nagrada najbolji e-mentor & e-author, <i>CARNet</i> .
Bibliografija:	http://bib.irb.hr/lista-radova?autor=292620 <i>GIMP</i> , E – course, <i>CARNet</i> , 2006., (http://www.carnet.hr/onlinetecajevi/gimp). E-course for E-mentors, E-course, <i>CARNet</i> , 2008., (http://www.carnet.hr/e-tecajevi_za_primjenu_u_nastavi/e_tecaj_za_e_mentore)
Programski jezici i aplikacije	C++, php, MySQL, HTML, CSS, XML, JavaScript, OWL, Ajax, jQuery, Photoshop, GIMP, Moodle, WebCT, Web servisi, SPARQL, Joomla, itd.

Biography

Name:	Tomislav Stipančić
E-mail:	tomislav.stipancic@fsb.hr
Date of birth:	09.07.1976.
Place of birth:	Zagreb, Croatia.
Education:	<p><u>2007. – 2013.</u>, Doctoral programme, Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, Croatia.</p> <p><u>1995. – 2006.</u>, B.Sc. programme, Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, Croatia,</p> <p><u>1991. – 1995.</u>, Secondary School, Zagreb, Croatia,</p> <p><u>1983. – 1992.</u>, Grammae School, Zagreb, Croatia.</p>
Additional Professional Education:	<p><u>2005. – 2006.</u>, E – learning Academy: E – tutoring programme (<i>ELA</i>, 2nd generation, Tutoring http://www.carnet.hr/education/e-learning_academy),</p> <p><u>2002. – 2003.</u>, Program for education of <i>CARNet</i> lecturers (Training the Trainers).</p>
Foreign Languages:	- fluent command of English.
Projects:	<p><u>2011. – today</u>, Researcher, “Neurosurgical Robots Application”, project supported by Croatian Institute of Technology, principal researcher prof. dr. sc. Bojan Jerbić.</p> <p><u>2009. – 2011.</u>, Researcher, “Improving <i>GRAsping</i> Movements by Predictions based on Observation”, <i>UKF</i> project financed by Ministry of Sciences, Education and Sports, <i>RH</i>, principal researcher prof. dr. sc. Danica Kragić.</p> <p><u>2008.</u>, Researcher, technological project “Automated Assembly with Dual Arm Robot System”, TP-08/0120-53, project supported by Croatian Institute of Technology, principal researcher prof. dr. sc. Bojan Jerbić.</p> <p><u>2007.</u>, Researcher, “Autonomous multiagent assembly”, scientific project no. 120-1201948-1941, financed by Ministry of Sciences, Education and Sports, <i>RH</i>, principal researcher prof. dr. sc. Bojan Jerbić.</p>
Positions:	<p><u>2010. – today</u>, Head of Laboratory for Manufacturing and Assembly System Planning, Faculty of Mechanical Engineering and Naval Architecture,</p> <p><u>2007. – today</u>, Scientific Novice, Faculty of Mechanical Engineering and Naval Architecture,</p> <p><u>2004. – today</u>, <i>CARNet</i> (Croatian Academic and Research Network), E-mentor expert.</p>

Scientific Development	<p><u>2012.</u>, April – May, research visit <i>URJC</i> Madrid, Spain.</p> <p><u>2009.</u>, June – July and 2011., January – February, research visit <i>KTH</i> Stockholm, Sweden.</p>
Awards:	<p><u>2009.</u>, Comenius-EduMedia-Awards, E-course for E-mentors,</p> <p><u>2009.</u>, Golden Tesla Medal, Ruđer Bošković Institute, awarded 1st prize for realized dual arm robotic setup.</p> <p><u>2009.</u> and <u>2010.</u>, Best e-lectures on <i>FMENA</i>, Faculty of Mechanical Engineering and Naval Architecture,</p> <p><u>2006.</u>, Best e-mentor & e-author, <i>CARNet</i>.</p>
Bibliography:	<p>http://bib.irb.hr/lista-radova?autor=292620</p> <p><u>2006.</u>, <i>GIMP</i>, E – course, <i>CARNet</i>, (http://www.carnet.hr/onlinetecajevi/gimp).</p> <p><u>2008.</u>, E-course for E-mentors, E-course, <i>CARNet</i>, (http://www.carnet.hr/e-tecajevi_za_primjenu_u_nastavi/e_tecaj_za_e_mentore)</p>
Programming Languages & Apps	<p>C++, php, MySQL, HTML, CSS, XML, JavaScript, OWL, Web Services, Ajax, jQuery, Photoshop, GIMP, Moodle, WebCT, Joomla, etc.</p>