

**Sveučilište „Jurja Dobrile“ u Puli
Fakultet ekonomije i turizma
“Dr. Mijo Mirković”**

Marin Gučić

Inteligentni poslovni agenti

Pula, svibanj 2015.

**Sveučilište „Jurja Dobrile“ u Puli
Fakultet ekonomije i turizma
“Dr. Mijo Mirković”**

Inteligentni poslovni agenti

Studijski smjer: Poslovna informatika

Predmet: ISPUO (Informacijski sustavi u potpori, upravljanju i odlučivanju)

Mentor: dr. sc. Vanja Bevanda, red. prof.

JMBAG: 183 – ED

Pula, svibanj 2015.

SADRŽAJ

1. Uvod.....	1
2. Potreba za inteligentnim agentima	3
3. Umjetna inteligencija	6
3.1 Grane umjetne inteligencije	10
4. Intelligentni agenti.....	12
4.1 Klasifikacija i komponente agenata	13
4.2 Pravno pitanje inteligentnih agenata	21
4.3 Utjecaj korištenja inteligentnih softverskih agenata	22
5. Semantički web - uvod u strukturu agenata	25
6. Struktura inteligentnih agenata.....	28
6.1 Programiranje inteligentnih poslovnih agenata	30
7. Analiza poslovnih aplikacija inteligentnih agentskih sustava.....	38
7.1 Primjer 1: Implementacija agentskog sustava za potrebe menadžmenta	39
7.2 Primjer 2: Implementacija agentskog rješenja u distribucijskom lancu maloprodaje	45
7.3 Primjer 3: Implementacija agentskog sustava u e-uslugama telekomunikacijskog poduzeća	57
8. Zaključak.....	67
9. Literatura	70

1. Uvod

Cilj ovog diplomskog rada je objasniti inteligentne softverske agente, njihovu pojavu i svrhu. Današnje informatičko doba ima svoje negativne karakteristike poput preopterećenosti informacijama (eng. information overload). Ova se fraza koristi za opisivanje pojave velike količine podataka i raznovrsnog sadržaja prvenstveno vezanog uz internet, ali i druge aspekte informatičkog doba. Prevelika količina informacija sa svojim drugim ekstremom, nedostatkom informacija, predstavlja stanje u kojem korisnik ne može kvalitetno donositi odluke jer nema potrebne informacije, odnosno nije u mogućnosti uvidjeti razliku između korisnih i beskorisnih informacija. U svijetu u kojem mogućnosti razmjene i skladištenja podataka rastu iz godine u godinu, preopterećenje informacijama će predstavljati sve veći problem.

Jedan krivac je arhitektura njegovog temelja, računala. Ono zahtijeva da čovjek direktno daje naredbe određenoj aplikaciji ili programu dok je računalo stavljeno u poziciju da samo reagira na podražaje korisnika. U području pretraživanja interneta to znači da čovjek određuje kako i što će se pretraživati. U ovakvoj situaciji se postavlja pitanje zna li čovjek što točno traži, odnosno kako to tražiti. Odgovor na ovo pitanje nudi se u obliku inteligentnih poslovnih agenata.

Oni predstavljaju samostalne aplikacije i programe koji djeluju uz korisnika umjesto da jednostavno reagiraju na naredbe istog. Agenti su sposobni učiti iz akcija svoga korisnika i tako upoznavanju njegove želje i preferencije. Glavni cilj ovakvih aplikacija jest svojim radom smanjiti opterećenje korisnika koje je posljedica preopterećenja informacija. Inteligentni agent, neovisno o domeni za koju je namijenjen, zamjenjuje korisnika u određenim stvarima, pogotovo u domeni pretraživanja. Agent takvu aktivnost može odraditi brže i efikasnije od korisnika. Računalo prelazi iz pozicije objekta na poziciju subjekta koji radi s korisnikom na ispunjavanju ciljeva.

Pri izradi diplomskog rada korištene su metode analize i dedukcije s postavljenim teorijskim temeljima u obliku znanstvenih radova i knjiga. Metode analize i dedukcije se odnose na skup od tri primjera koji predstavljaju praktična rješenja na odabranu temu. Cilj rada je dobiti odgovor na sljedeću hipotezu : „Kakav utjecaj ima implementacija inteligentnih agenata na poslovanje i je li njihovom primjenom moguće unaprijediti poslovne funkcije?“. Odgovor na postavljenu hipotezu je prezentiran u sedmom poglavlju rada u kojem se nalaze već napomenuta praktična rješenja. Primjeri sadrže praktičnu primjenu agentske tehnologije i

zaključak, i kao takvi su prikladni za dokazivanje navedene hipoteze. I finalno, odgovor na postavljenu hipotezu je prezentiran u zaključku rada.

2. Potreba za inteligentnim agentima

U samom uvodu je rečeno kako je središnji problem informacijskog doba „poplava“ informacija. Korisnik je svjestan toga. Pretpostavimo da sam ja korisnik i tražim određenu pjesmu koju sam čuo na radiju. Problem je što ne znam naslov pjesme i izvođača. Logično rješenje je pretražiti pjesmu pomoću pretraživača uz pomoć teksta kojeg se sjećam. Problem u pretraživanju prema tekstu je što postoji velik broj pjesama koje imaju sličan tekst. Zbog velikog broja rezultata na pretraživaču želja pronalaska naslova i izvođača pjesme postaje zadatak „traženja igle u plastu sijena“. Jedina mogućnost je pojedinačno preslušati svaku pjesmu što je veliki gubitak vremena. Radi velike vjerojatnosti nepronaska traženog rezultata, prisiljen sam odustati od zahtjeva.

Ako u ovaj scenarij uključim agenta, mogu dati parametre koje dosada nisam mogao zbog ograničenja pretraživača. Znam da je izvođač žensko, da je pjesma laganog ritma, da otprilike traje oko tri minute i da pripada pop glazbi. I u ovome scenariju znam da postoji mogućnost nepronaska pjesme. Inteligentni agent može pretražiti internet efikasnije od korisnika. Velika prednost ovog scenarija je da korisnik nije prisutan tijekom procesa pretraživanja, agent pretražuje umjesto korisnika. Korisnik treba samo pregledati rezultate pretrage i s agentom korigirati parametre pretrage ako je potrebno. Ovaj scenarij ne jamči da će naći traženu pjesmu, ali uvelike povećava vjerojatnost za to.

Ilustracija potrebe za agentima može se prikazati na primjeru različitosti između knjižnice i interneta. Razliku je što je internet digitalan, a knjižnica analogna (stvarno mjesto u vremenu i prostoru). Sličnost je što su oboje „centri informacija“ te pohranjuju podatke. U slučaju knjižnice podaci se pohranjuju u knjige, časopise koji se organiziraju u vrlo jasne kategorije (medicina, prirodoslovne znanosti, avantura, triler...). Knjiga je smještena u jednu od spomenutih kategorija. Svaka knjiga u knjižnici ima jedinstvenu šifru po kojoj se može naći. Tako svaka knjiga ima svoje mjesto unutar knjižnice. Korisnik knjižnice uvijek može naći knjigu, odnosno informaciju koja mu je potrebna, jer se ona uvijek nalazi na istome mjestu. U knjižnici postoji mogućnost korisnikovog nepronaska knjige (ako ju knjižnica ne posjeduje ili ako je knjigu već netko posudio). Tako ta informacija postaje korisniku nedostupna. Internet ima sličnu koncepciju, uz određene razlike.

Prva je razlika u dinamičnosti centara. Knjižnica je statičan element u odnosu na internet. Informacije unutar knjižnice rijetko mijenjanju svoje mjesto ili značenje. Internet je mjesto koje nema jedan specifičan način pohrane podataka te količina podataka pohranjena u

njemu konstantno raste. Za podatke koji se danas nađu na internetu postoji mogućnost da sutra više neće biti ili će se prekosutra pojaviti na drugom mediju i mjestu.

Druga je razlika u količini dostupnih informacija. Oba centra imaju agente. Knjižnica ima knjižničare koje nam pomažu s upitima i imaju znanje gdje se nalaze tražene informacije. Kada bismo dali fizičku veličinu podacima na internetu prostor bi bio velik kao i prekooceanski tanker. Tu veličinu samo tvore serveri i hard diskovi koji drže podatke. Kada bismo sve te podatke prenijeli u knjige (medij knjižnice), koliki fizički prostor bismo zauzeli? Imali bismo toliku količinu knjiga da bi knjige „naslagane jedna na drugu prešle udaljenost između Zemlje i Pluta 10 puta“¹.

Treća je razlika kvaliteta i važnost informacija. U knjižnici kvaliteta informacija je riješeno pitanje tako što autor knjige jamči istinitost informacija unutar nje. Internet slijedi ovaj primjer zaštite omogućavajući razne vrste zaštite informacija i podataka poput digitalnog potpisa. Oba centar imaju svoje podjele informacija na kategorije (ekonomija, zabava, beletristika...). Knjižnica ove podjele primjenjuje i u fizičkom obliku (odjel za ekonomiju, fiziku...). Internet podatke o temama drži u sajtovima, torrentima te drugim medijima koji su raštrkani kroz cijeli internetski prostor. Unutar ove razlike se pokazuje i zajednička karakteristika, nećete znati kvalitetu i korisnost određene knjige i njezinih informacija dok ju ne pročitate.

Zamislite knjižnicu koja nema jasno odijeljene odjele tako da ne znate gdje trebate tražiti knjigu i informacije koju su vam potrebne. Ta knjižnica ima svoje knjižničare, ali zbog nekog razloga se teško sporazumijevaju sa korisnikom. U takvom oceanu knjiga koje nemaju jasnu podjelu niti prebivalište teško se orijentirati. Čak i ako se korisnik zna orijentirati, prisiljen je prolaziti oceane podataka da dođe do nekoliko korisnih informacija. Pomoć od knjižničara ove knjižnice je ograničena. Razlog tome je korisnikova nesposobnost preciznog zahtjeva knjižničaru. Sedamdeset posto svih podataka koje ovakva „knjižnica“ sadrži su nevažne. Ta knjižnica je internet, a njezini knjižničari su inteligentni agenti.

Potreba za agentima, odnosno inteligentnim agentima je jednostavno rečeno potreba korisnika za softverom koji će umjesto njega obavljati pretraživanje i filtriranje informacija. Pritom se misli prvenstveno na nepotrebne informacije. Agent je u rječniku ovlaštena osoba koja obavlja aktivnosti u ime druge osobe. Ne postoji opće prihvaćena definicija od strane akademika. Prema Russelu i Norvigu (1995.) agent je „entitet koji može percipirati svoju

¹ <http://www.theguardian.com/business/2009/may/18/digital-content-expansion>, uzeto 20. 7. 2014.

okolinu i utjecati na nju kroz efekte². Naravno, postoje detaljnije definicije poput Maesove³: „Računalni sustav koji radi u dinamičnoj i kompleksnoj okolini, percipira, radi samostalno i time ostvaruje set ciljeva za koji je dizajniran.“. Neke definicije samo napominju karakteristike inteligentnog agenta. Wooldridge and Jennings⁴ govore kako je inteligentni agent „hardverski ili softverski kompjuterski sustav koji ima svojstva autonomije, socijalne prilagodbe, reaktivnosti i proaktivnosti“. Jedina stvar oko koje se akademici slažu je da agenta najbolje definira autonomija, sposobnost djelovanja bez korisnika što je njegovo temeljno obilježje.

Prema podacima⁵:

- količina podataka prikupljena svake godine se udvostruči
- data programeri mogu analizirati samo otprilike 5 % podataka
- većina rada s prikupljenim podacima je traženje veze između podataka (otprilike 60 %), tek 20 % spada na razumijevanje veze između podataka, a još manji postotak se daje na praktičnoj primjeni otkrivenih veza (otprilike 10 %)
- preopterećenost informacijama reducira sposobnost odlučivanja za 50 %

Navedeni podaci pokazuju koliko je važno unaprijediti mogućnosti skupljanja, filtriranja i analize informacija. Informacija da preopterećenost uzrokuje smanjenje sposobnosti odlučivanja za pedeset posto nije stvar koju menadžment određene tvrtke može ignorirati. Sama razina postotka samo prikazuje veličinu problema. Ali i prikazuje drastičnu mogućnost za poboljšanje. Ako raširenija implementacija agenata može smanjiti ovaj postotak za recimo dvadeset posto, onda će to rezultirati i kvalitetnijim poslovnim odlukama. To, naravno, rezultira većom razinom profita za tvrtku što je cilj prevladavajućeg dijela poslovnih subjekata. Prije poglavlja u kojem će se definicija inteligentnih agenata prikazati i objasniti najprije se mora prikazati iz koje informatičke domene dolaze inteligentni agenti. Zato će se sljedeće poglavlje baviti područjem umjetne inteligencije, skraćeno UI-a.

² I. S. Rudowsky, *Intelligent Agents*, Communications of the Association for Information Systems, Volume 14, London, 2004., str. 276.

³ Efraim, T. Ramesh E, S. Dursun, D. , *Business Intelligence and Analytics: Systems for Decision Support* - 10th edition, Prentice Hall, New Jersey, 2010., str. 705

⁴ I. S. Rudowsky *op. cit.*, str. 279

⁵ Efraim, T. Ramesh E, S. Dursun, *op. cit.*, str. 709

3. Umjetna inteligencija

Kako bi se tema inteligentnih poslovnih agenata mogla detaljnije obraditi potrebno je predznanje o komponentama koje čine samu cjelinu agenta. To znači poznavati njihovu konstrukciju, način i strukturu po kojoj su rađeni. Prva od tih karakteristika je domena umjetne inteligencije. Za umjetnu inteligenciju se u nastavku koristi kratica UI. Ovo je područje računalne znanosti koje se bavi pitanjem inteligencije, odnosno pitanjem stvaranja inteligencije. Jedna od dobro poznatih definicija je: „Umjetna inteligencija je ponašanje stroja koje bi, ako je napravljeno od strane čovjeka, bilo smatrano inteligentnim.“⁶. Jednostavnija definicija govori: „Umjetna inteligencija je znanost koja pokušava da strojevi rade stvari koje trenutačno ljudi rade bolje.“⁷. Znači UI je znanost o samom pitanju inteligencije. UI ima temelje u velikom broju drugih znanosti. Filozofija, matematika, ekonomija, neuroznanost, psihologija, računalna znanost, kibernetika, lingvistika itd. Svaka navedena znanost daje svoj doprinos pitanju UI-e. Koliko je područje UI-e rašireno prikazano je na slici 4 gdje je prikazano grananje „stabla“ UI-a. Prije detaljnog objašnjavanja našeg „stabla“ UI-a, mora se napomenuti da unutar njega postoje četiri različite struje misli. Zašto su nazvane struje? Zato jer predstavljaju konceptualne razlike koje čine zasebne tijekove misli od kojih svaka ima različito mišljenje o tome što je zapravo inteligencija, odnosno kako pristupiti pitanju UI-e. Te struje su:

1. **ljudsko razmišljanje** – „Uzbudljiv i nov pokušaj da računala razmišljaju... stojevi s umom, u punom i doslovnom značenju.“⁸. Racionalno razmišljanje je zaključivanje na osnovi tri stvari: cilja, dostupnih činjenica i logičkog slijeda. Kognitivna znanost pokušava otključati principe koje čine takvo razmišljanje mogućim. S time da se kognitivna znanost prvenstveno bavi pitanjem kako radi ljudska i životinjska inteligencija. Ova struja prilazi pitanju inteligencije kroz kognitivnu znanost. Ovaj pristup se zove kognitivno modeliranje, odnosno pristup uzimanja saznanja iz jedne grane znanosti i prenošenje na drugu. Mora se napomenuti da kognitivna znanost nije dio znanosti UI-e, ali se zbog istog cilja (shvaćanje inteligencije i njezinih principa) razvijaju u simbiotskom odnosu;

⁶ Stuart, R. Peter, N., Artificial intelligence – a modern approach, Pearson Education Inc. , New Jersey , 2010., str. 2

⁷ *loc. cit.*

⁸ *ibidem, str. 3*

2. **racionalno razmišljanje** – „Proučavanje komputacija koje čine mogućim percepciju, misli i akciju.“⁹. Struja racionalnog razmišljanja želi u UI-i usmjeriti fokus na „pravilno razmišljanje“ koristeći principe racionalnosti i logike. Unutar područja UI-e takvi akademici se zovu „logički tradicionalisti“ jer žele stvoriti inteligentne sustave koji kroz prizmu logike i logičkih sljedova pokušavaju aproksimirati inteligenciju. Kod takvog pristupa se javljaju dvije zapreke. Prva je da se potrebno informalno znanje može opisati i definirati logičkim notacijama i opisano znanje mora biti u potpunosti točno. Druga je da teoretsko rješavanje problema nije jednako ili u potpunosti primjenjivo u praksi. Primjena takvog postupka logike na problemu koji ima nekoliko stotina logičkih izjava rezultirala bi stanjem u kojem bi računalo iscrpilo mogućnosti izračuna rješenja. Opisane prepreke su prisutne kod svake metode i svakog pokušaja stvaranja UI-e, a ovdje se očituju prve;
3. **ljudsko ponašanje** – „Proučavanje kako napraviti da računala rade stvari koje u ovom trenutku ljudi rade bolje.“¹⁰. Ova struja pokušava dostići inteligenciju tako da je uspoređuje s ljudskom. Dakle, stroj je inteligentan ako ne postoji razlika između njegovog razmišljanja i ljudskog. Najbolji primjer je Turingov test, smišljen 1950. godine. Test se izvodi na sljedeći način. Ispitivač, pri tome se misli na osobu, ispituje računalo kroz seriju pisanih pitanja. Računalo je položilo ako ispitivač ne može raspoznati daje li odgovore čovjek ili računalo. UI koja je sposobna proći ovakav test mora biti sposobna komunicirati s korisnikom, imati karakteristike reprezentacije znanja, automatiziranog razmišljanja i strojnog učenja. Činjenica je da ovaj test šezdeset godina nakon svoje kreacije zadržava važnost kao relevantni test stvarne inteligencije. Isto tako, do dan danas niti jedna UI nije prošla test. Ali reproduciranje ljudske inteligencije tako da se dođe do faze gdje nećemo moći razlikovati ljudsku i računalnu inteligenciju ne odgovara na pitanje što je to inteligencija. Ljudsko razmišljanje nije toliko važno koliko principi i zakonitosti koji ga stvaraju. Cilj aerodinamike nije savršena imitacija leta ptica, nego shvaćanje principa koji omogućavaju taj let. Zato ova struja nije toliko zastupljena u UI-i;


⁹ *ibidem*, str. 4

¹⁰ *ibidem*, str. 2

4. **racionalno ponašanje** – „Računalna inteligencija je proučavanje dizajna inteligentnih agenta.“¹¹ Racionalnost možemo nazvati drugim imenom „zakonitošću razmišljanja“. Ona ima nekoliko karakteristika koje mogu olakšati stvaranje agenata. Racionalnost ćemo podobnije objasniti u daljnjem tekstu. U ovom pristupu fokus je stvoriti UI-u koja generira pravilne zaključke. Jedan od područja koje spadaju pod racionalnost jest postupak pravilnog zaključivanja bez uplitanja korisnika. Anatomija zahtijeva da agent ima sposobnost pravilnog zaključivanja s obzirom na cilj. Logično je pitanje zašto je ovaj pristup UI-e bolji za stvaranje agenta od ostalih. Odgovor je da se agent može kreirati kroz bilo koju od navedenih struja, ali kroz racionalno ponašanje. Racionalnost ima nekoliko prednosti nad drugim pristupima. Prva je što racionalnost obuhvaća veći pojam od pukog pravilnog zaključivanja. Ako pravilno zaključivanje nije moguće u odnosu na situaciju, racionalnost ima druge mehanizme kojima se ostvaruje. Drugo, struja racionalnog ponašanja pruža veću mogućnost reprogramiranja i manipulacije nego pristupi replikacije ljudskog razmišljanja ili ponašanja. Jedan dio toga je jer je racionalnost matematički bolje definirana od prije navedenih i još važnije, generalna je po svojoj prirodi. To daje mogućnost da se ovaj pristup uzme i jednostavno modificira za potrebe određenog agenta. Kod, recimo, replikacije ljudskog razmišljanja, taj postupak nije tako jednostavan. No, ovaj pristup ima nedostatake. Jedan od njih je što savršenu, odnosno optimalnu racionalnost nije moguće ostvariti u kompleksnim okolinama. Komputacijski zahtjevi jednostavno to trenutačno onemogućuju.

¹¹ *ibidem*, str. 4

Slika 1: Stablo UI-e



Izvor : Efraim, T. Ramesh E, S. and Dursun, D., Business Intelligence and Analytics: Systems for Decision Support (10th edition), Prentice Hall, New Jersey, 2010.

Nakon što su prikazane ove četiri struje, prelazi se na veličinu koju znanost UI-e zauzima. Prva stvar kod „stabla“ UI-e je velik broj korijena, odnosno temelja. Od sociolingvistike do filozofije, preko računalne znanosti, do čiste teorijske matematike. Potreban je veliki broj znanstvenih domena jer odgovor na pitanje što je inteligencija ne može dati samo jedna domena. Svaki od navedenih i prikazanih korijena daje svoj dio znanja da bi stvorio potpuniju sliku UI - e. Stablo se dalje širi u veliki broj grana koje pokušavaju aproksimirati ljudsko znanje o inteligenciji. Teorije igara, neuronske mreže, strojno učenje, genetički algoritmi, fuzzy logika, ekspertni sustavi. Sve su to grane koje nude odgovore na isto pitanje, ali kroz različite tehnike i perspektive. Mora se napomenuti kako sve grane odgovaraju na isto pitanje, ali nemaju iste ciljeve. Cilj ovog rada je promatranje poslovnih inteligentnih agenata. Dakle, kod UI-e to znači znati i razumjeti kako stvoriti inteligentni

sustav koji autonomno može zaključivati i djelovati. Cilj rada nema nikakve veze s generiranjem i analiziranjem ekspertnog znanja (ekspertni sustavi) ili robotike (kreiranje prvog inteligentnog robota). Tako da su u nastavku obrađene samo neke grane UI-e.

3.1 Grane umjetne inteligencije

Stablo UI-e ne prikazuje samo područja odnosno domene nego i metode koje podržavaju iste. Ako se znanost UI-e podijeli tako da možemo promatrati koje su različite vrste metoda stvaranja inteligencije, prezentira se određeni problem. Kao i kod definicije agenta, postoje razne podjele. Za potrebe rada uzeta je podjela koja je prikazana na stablu UI-e.

Ekspertni sustavni (eng. expert systems) su inteligentni sustavi koji koriste ljudsko znanje, odnosno ekspertno znanje, za rješavanje problema. Cilj ovih sustava je predočiti znanje tako da ga računalni sistemi mogu razumjeti i primijeniti.

Neuronske mreže (eng. neural networks) su set matematičkih modela koji simuliraju funkcioniranje ljudskog mozga. Oni su fleksibilni i lako modularni te su zbog tih razloga u velikoj mjeri prisutni u poslovanju.

Robotika (eng. robotics) uključuje senzore, taktilne, mehaničke i elektronične sustave koje u kombinaciji s UI-om obavljaju određene zadatke. Uglavnom se koriste u proizvodnoj industriji kao zamjena ljudskog manualnog rada. UI predstavlja mozak koji interpretira informacije o okolini i reagira na percipirane promjene.

Glasovno razumijevanje (eng. speech understanding) bavi se metodama i tehnikama potrebnim za računalno razumijevanje ljudskog govora. Poslovna implementacija ove domene je raširena u računalnim sistema poput pametnih mobitela. Apple-ova aplikacija Siri je primjer komercijalizacije istog.

Teorija igara (eng. game playing) – jedna od prvih domena UI-e koja se razvila. Cilj je kroz razne algoritme stvoriti računalnu inteligenciju koja može učiti i analizirati poteze, odnosno akcije ljudskog protivnika. Ova domena UI-e je uvelike zastupljena u videoigramama.

Obrada prirodnog jezika (eng. natural language processing) – bavi se stvaranjem tehnologije koja omogućava računalu komuniciranje s korisnikom na njegovom jeziku. Ovo je alternativa strojnim, odnosno programskim jezicima koji koriste

računalni žargon, sintaksu i naredbe. Predstavlja želju da računala razumiju ljudski jezik te nastoji uvesti višu razine komunikacije i razumijevanja s korisnikom.

Prevođenje jezika (eng. language translation) – cilj je stvoriti univerzalnog strojnog prevodioca koji je sposoban prevoditi ljudske jezike bez intervencije korisnika.

Genetički algoritmi (eng. genetic algorithms) – metoda koja koristi napredne algoritme da replicira prirodnu evoluciju. Unutar nje su uključeni evolucijski koncepti poput mutacije. Algoritam počinje od seta randomiziranih vrijednosti u odnosu na zadani cilj. Vrijednosti se nalaze u raznim varijacijama i to u „kromosomima“. Kromosomi se međusobno povezuju kako bi formirali nova rješenja koja prolaze proces neprestane interakcije, odnosno evolucije. Evolucijski proces se nastavlja dok se cilj ne ispuni na zadovoljavajući način.


Fuzzy logika (eng. fuzzy logic) – tehnika koja se koristi za procesiranje lingvističkih termina. Koristi se u UI-i zato što proširuje logičke termine poput istinito-lažno. Fuzzy logika daje mogućnost da izjava može biti istinita i lažna, ali u jasno određenim stupnjevima. Primjerice izjava da UI omogućava stvaranje inteligencije je istinita, ali je ujedno i lažna zato što je do sada stvorena samo aproksimacija inteligencije.

Unutar prijašnjeg poglavlja obrađena je tema UI-e i koncept iste. Objašnjene su i struje koje predstavljaju osnovne razlike u filozofiji, odnosno četiri zasebna razmišljanja oko pitanja inteligencije. Ovo poglavlje je ukratko predstavilo koje su grane, odnosno domene ove znanstvene discipline. Pitanje se postavlja zašto. Prvi razlog je što tema poslovnih inteligentnih agenata ne može biti započeta ako se ne dodirnemo definicije i domene tog područja, ali i metoda kojima se umjetna inteligencija stvara. Drugi je što struje postoje zasebno od grana UI-e. Bez znanja da postoje različite filozofije o tome što je inteligencija, odnosno struje, bez povezivanja struja s granama i metodama, ne može se prikazati koje su mogućnosti kod stvaranja inteligentnih agenata. Struje daju odgovor konceptualne utemeljenosti razmišljanja agenata, odnosno akcije agenata. Grane UI-e daju moguće metode i načine izrade. Kombinacija jednog s drugim daje sliku na koji način će se agent ponašati i metodu koja stvara takvo ponašanje. Treći je razlog, usprkos tome što inteligentan agent dobiva svoju inteligenciju, odnosno aproksimaciju inteligencije na navedene načine, to što načini nisu tema ovoga rada, tako da ta grana znanosti mora biti teorijski spomenuta i objašnjena, ali ne i obrađena na detaljnoj razini. Ponovno se može postaviti sljedeće pitanje, zašto. Odgovor je jednostavan, ali nije očit. Najvažnija odlika poslovnog inteligentnog agenta nije inteligencija, nego autonomija, odnosno samostalnost. Sposobnost da obavlja akcije bez

korisnika, ali u njegovo ime. U nastavku je prikazano da ne postoje samo inteligentni agenti, nego cijele dimenzije podjela agenata prema različitim kriterijima. Oni svi imaju istu karakteristiku, autonomiju. Ona je glavna razlika između agentskog programa ili koda i bilo kojeg drugog programa ili koda.

4. Inteligentni agenti

U dosadašnjem dijelu rada spomenuto je da preopterećenost informacijama može imati paralizirajući efekt na korisnika. Korištenje interneta je najbolji primjer. Rješenje za ovaj informacijski problem stvoreno je u konceptu inteligentnog agenta. Jednostavan primjer agenta se nalazi na slici 2.



Izvor: Michael.W., *Intelligent Agents*, MIT Press, Cambridge, 1998.

Koncept agenta je jednostavan. On percipira svoju okolinu kroz senzore, uzima informacije od njih, analizira ih i traži akcije koje može izvršiti. Iz slike se vidi kako je proces agenta interaktivan i iterativan proces. Postoji razlika između agenta i inteligentnog agenta. Tri su karakteristike koje inteligentni agent ima u odnosu na ostale agente. To su:

1. **reaktivnost** (eng. reactivity) – mogu percipirati svoju okolinu i reagirati na promjene u njoj, u određenom vremenskom roku, u skladu sa zadanim ciljem,
2. **proaktivnost** (eng. proactiveness) – u skladu sa svojim ciljem agent može reagirati samoinicijativno i unaprijed reagirati na promjene u svojoj okolini,

3. **komunikacija s drugima** (eng. social ability) – može komunicirati s drugim agentima i sa samim korisnikom.

4.1 Klasifikacija i komponente agenata

Klasifikacija između raznih agenata može se uspostaviti i utvrditi. Agent je po svojoj definiciji softver koji s korisnikom ostvaruje određeni zadatak. Područje primjene ove vrste softvera je ograničeno prvenstveno tehnologijom. Klasifikacija ima smisla samo ako podijelimo agenta prema domeni u kojoj mora djelovati¹²:

- ❖ **agenti za kadrovski i poslovni menadžment** (eng. agents for workflow and business management)
- ❖ **agenti za distribuirano opažanje** (eng. agents for distributed sensing)
- ❖ **agenti za pronalaženje i menadžment** (eng. agents for retrieval and management)
- ❖ **agenti za korisnik-računalo interakciju** (eng. agents for human-computer interaction)
- ❖ **agenti za virtualna okruženja** (eng. agents for virtual environments)
- ❖ **agenti za socijalnu simulaciju** (eng. agents for social simulation).

Teoretski, agent može djelovati, odnosno biti kreiran za bilo koju akciju u kojoj komuniciraju čovjek i računalo. Ova podjela se mora razumjeti kao podjela mogućih primjena inteligentnih agenata. Vidljivo je da podjela obuhvaća većinski dio ljudskog postojanja i interakcije s drugima. Time se jasno ilustrira golemi potencijal inteligentnih agenata.

Karakteristike inteligentnih agenata¹³ :

1. **reaktivnost** (eng. reactivity) – sposobnost agenta da percipira okolinu i reagira pravovremeno na promjene u cilju ispunjavanja zadatka,
2. **proaktivnost** (eng. proactiveness) – sposobnost agenta da ciljano poduzima aktivnu ulogu u okolini, odnosno inicijativu u skladu sa zadanim ciljem,
3. **socijalna sposobnost** (eng. social ability) – sposobnost agenta da komunicira s drugim agentima (i moguće ljudima) u skladu s ciljem,

¹² Efraim, T. Ramesh E, S. and Dursun, D. *op. cit.*, str. 707

¹³ *ibidem*, str. 712

4. **autonomnost** (eng. autonomy) – agentova sposobnost kontrole nad svojim akcijama i njihovog izvršavanja neovisno o korisniku ili drugom agentu.

Razine inteligencije¹⁴ :

0. razina

Najniži nivo inteligencije. Agent poduzima akcije samo ako je u pitanju direktna naredba korisnika. Web preglednici spadaju ovdje. Korisnik mora definirati URL (eng. uniform resource locator) adresu. Agenti ove razine pomažu s navigacijom na internetu.

1. razina

Agenti ove razine daju pretraživačke mogućnosti za traženje relevantnih internet stranica. Najpoznatiji pripadnik ove razine je Google tražilica. Naziv tražilica je često i ime za agente ove razine. Agenti po principu ključnih riječi uspoređuju riječi koje unese korisnik s već indeksiranim informacijama.

2. razina

Agenti ove razine su sposobni održavati korisničke profile. Prate internetske informacije i daju obavijesti kada je relevantna informacija nađena. Primjer ove razine je WebWatcher, agent koji se koristi u svrhu turizma. Ovi agenti se nazivaju i semi-inteligentnima ili softverskim agentima.

3. razina

Agenti ove razine imaju sposobnost učenja i dedukcije u svrhu pomaganja korisniku pri formaliziranju upita ili željene akcije. DiffAgent i Letizia su primjeri takvih agenata. Ti agenti se nazivaju stvarno inteligentnima agentima.

Komponente agenta¹⁵

Vlasnik (eng. owner) – može biti korisničko ime glavnoga procesa ili glavnoga agenta (eng. master agent). Agent može imati više vlasnika. Jednako tako, korisnik ili sam proces može kreirati agenta za određenu zadaću. Pritom se misli da agent može započeti svoje procese ili može bit aktiviran od strane drugih agenata. Primjerice praćenje cijena dionica kada se ispune zadani parametri.

¹⁴ *loc. cit.* 715

¹⁵ *ibidem, str.* 712

Autor (eng. author) – kao i kod vlasnika, autor može biti: korisnik, softverska kuća, zasebni proces ili glavni agent. U slučaju autora koji nije čovjek agent može biti kreiran kao osnovna šablona koju korisnik može prilagoditi svojim potrebama.

Račun (eng. account) – agent mora imati čvrstu poveznicu koja ga povezuje s vlasnikom za potrebe naplate usluge ili kao točka izvorišta.

Cilj (eng. goal) – potrebna je jasna definicija cilja agenta kao i popratna metrika kojom će se pratiti cilj. Najlakše je ako je cilj definiran u formi izjave. Metrički podaci daju nam informacija u kojoj je fazi zadatak, ali nam daju i konačni rezultat zadatka. Praćenje može biti jednostavno poput jednostavne dvosmjerne transakcije, ali i puno kompleksnije (uključuje vrijeme trajanja procesa, broj obrađenih podataka itd.).

Opis subjekta (eng. subject description) – nadovezuje se na komponentu cilja. Sadrži atribute samoga cilja. Agent kroz ovu komponentu dobiva ograničenja unutar kojih mora operirati, zadatke (akcije) koje mora poduzimati i moguće resurse koji su mu dostupni. Tu se nalazi i klasifikacija potrebe (npr. cijena avionskih karata, sniženja, cijena dionica).

Stvaranje i trajanje (eng. creation and duration) – sadrži informacije o datumu stvaranja agenta, datumu trajanja zahtijeva i ostvarenja cilja.

Okolina (eng. background) – predstavlja informacije o okolini u kojoj agent djeluje, ali i mjesto njegovog djelovanja.

Inteligentni podsustav (eng. intelligent subsystem) – predstavlja komponentu koja omogućava agentu inteligentno ponašanje. Sadrži informacije o tome kako agent donosi svoje odluke i kroz koje parametre. Sustav može biti baziran na principu neuralne mreže ili ekspertnog sustava. Baza može biti i neki drugi princip inteligentnog programiranja.

Glavna razlika između agenta i inteligentnog agenta je da inteligentni agent unutar sebe ima određenu komponentu koja pripada domeni umjetne inteligencije. On aproksimira ljudsku inteligenciju. Zamišljeni su za rad u ime ljudskog korisnika u sljedećim domenama ljudskog rada¹⁶:

- ❖ **potpora odlučivanju (eng. Decision support)** – informacija pravilno provjerena i pravovremeno dostavljena može značiti razliku između dobre ili loše poslovne odluke. Filtrirana informacija od strane agenta drastično povećava mogućnost efektivnog menadžmenta;

¹⁶ *ibidem*, str. 710

- ❖ **potpora odlučivanju s vanjskim subjektima (eng. frontline decision support)** – zaposlenici koji imaju komunikaciju s vanjskim subjektima sada imaju priliku uspostaviti komunikaciju na razini koja prije nije bila moguća. Odnos kupca i zaposlenika sada ima mogućnost biti jasniji i dublji nego prije jer agent može dati informacije o kupcu (preferencije i želje) prije uspostavljanja komunikacije;
- ❖ **ponavljajuće uredske aktivnosti (eng. repetitive office activities)** – određene uredske aktivnosti, primarno uredska papirologija i birokratske aktivnosti mogu biti preuzete od strane agenata koji taj posao mogu obavljati efikasnije i uz puno manji trošak novca i vremena;
- ❖ **pretraga i ekstrakcija (eng. search and retrieval)** – današnji agenti mogu pregledati velike količine podataka (npr. baza podataka) efikasnije i brže nego korisnik i izvući ih. Tako se smanjuje vrijeme koje korisnik mora potrošiti na pretragu i daje mu se mogućnost da to vrijeme provede na praktičnoj primjeni traženog podatka;
- ❖ **stručno znanje (eng. domain experts)** – agenti daju mogućnost modeliranja određenog stručnog znanja, npr. domene prava, diplomacije, prevođenja itd. Tako generirano znanje se može staviti na raspolaganje javnosti kroz medij agenta koji može dati stručno mišljenje na određenu domenu uz frakciju istog troška (npr. cijena pravnog savjeta od strane stručnjaka).

Naravno, tehnologija i znanje na današnjoj razini ne može stvoriti agenta koji se može prilagoditi i djelovati u okruženju na način koji objektivno prikazuje da je inteligentan. Ali, moguće je stvoriti softver dovoljno kompleksan da korisnik može dobiti iluziju inteligencije. „Inteligentni agenti su zapravo 99 % računalna znanost i 1 % umjetna inteligencija.“¹⁷. Glavna komponenta agenta nije njegova inteligencija, nego autonomija. Sposobnost samostalne interakcije s okolinom u ime korisnika. Jednostavnije rečeno, agent je softver koji može percipirati želje korisnika, bile one jasno definirane ili ne. Njemu je dovoljno reći što želimo, dok je pitanje u domeni koja pripada agentu.

Inteligentni agenti su prisutni i, kao što je spomenuto, njihove domene rada zaista obuhvaćaju veliki dio ljudske aktivnosti. To je prikazano u Tablici 1.

¹⁷ I. S. Rudowsky *op. cit.*, str. 275

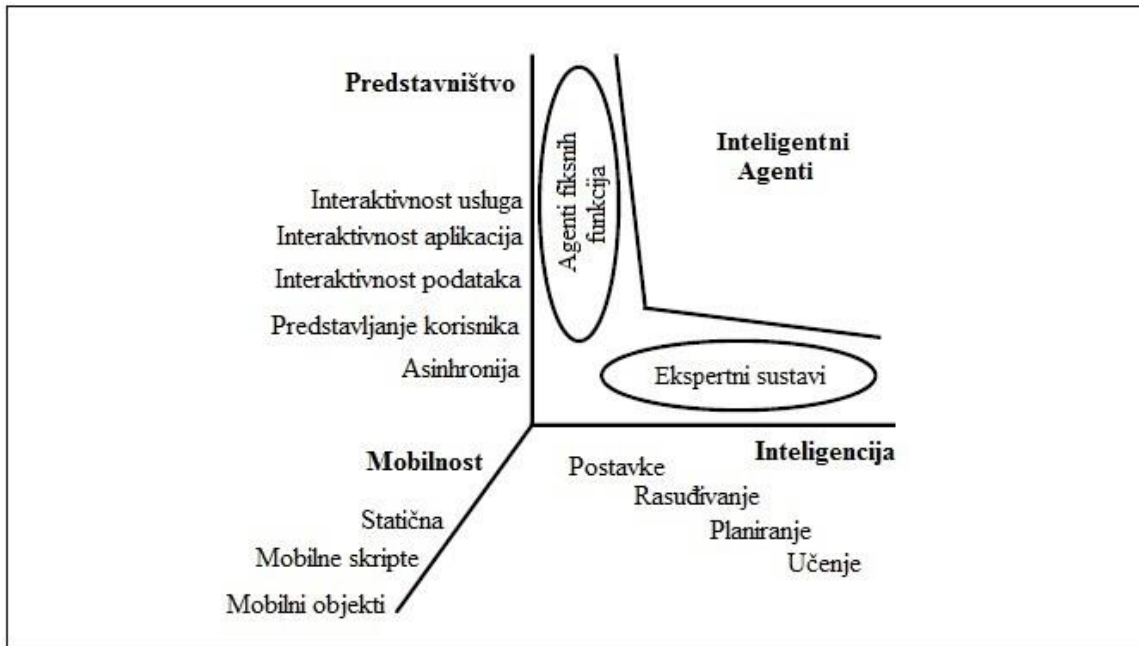
Tablica 1: Primjeri dostupnih agenata

Agent	Percepcija	Akcije	Ciljevi	Okolina
Google tražilica	web-stranice, traženi pojmovi	pretražiti internet, skupiti infomacije	naći najbolje rezultate vezane za upit	internet
ALVINN	slike, pozicija	upravljanje volanom, kontrola brzine	vožnja od točke A do točke B	cesta, automobili, prometne opasnosti
Deep Blue	trenutačno stanje šahovnice	odabrati sljedeći potez	pobjediti	protivnik, šahovnica
Open Sesame	Macintosh procesor	praćenje i analiza aplikacija koje se koriste	odrediti i izdvojiti repeticijske akcije korisnika	Macintosh procesor
Hoover	baze podataka, internet, web-portali raznih novinskih publikacija	sakupljanje i organizacija podataka	dati korisniku informacije i kontekst	internet, baze podataka

Izvor: prilagođeno prema Efraim, T. i ostali (2010.)

Tablica 1 prikazuje neke od postojećih agenata kroz četiri kategorije. Svrha ove tablice je predstavljanje agenata koje neki od nas koriste ili su koristili bez znanja da su oni agenti (Google tražilica). Agenti su zastupljeni u računalnoj tehnologiji od 50-ih godina prošlog stoljeća i ova tablica služi kao podsjetnik tome. Prva od kategorija tablice je **percepcija**, dio okoline koji predstavlja posebnu važnost u odnosu na sam cilj. Percepcija je dio okoline koji je praćen od agenta. Bez nje agent ne može pratiti promjene u svojoj okolini i reagirati na njih. Jednostavnije, percepcija je način na koji agent ostvaruje povratnu vezu između okoline i svojih akcija. Druga kategorija, **akcije**, predstavlja skup radnji koje agent obavlja. Kroz njih on mijenja okolinu i postiže cilj. Kategoriju **ciljevi** čine jedan ili više zadataka koje agent mora ispuniti i koji određuju njegove akcije. Četvrta je **okolina** koja predstavlja mjesto u kojem agent mora ispuniti cilj i unutar kojeg djeluje.

Slika 3: Dimenzije i vrste agenata



Izvor: Jeffrey M. B., *Software Agents*, MIT Press, Cambridge, 1997.

Bolje ćemo razumijeti agente ako pogledamo sliku 3 koju čini dimenzionalan prikaz inteligentnih agenata. Prikazane su tri dimenzije agenata¹⁸:

predstavništvo (eng. agency) – predstavlja razinu automnosti koju agent ima u odnosu na njegovu funkciju, ali i razinu ovlasti koje su mu dane od strane korisnika. Vidljivo je da rangira od asinkronizacije do mogućnosti interakcije s aplikacijama, podacima i servisima. Ova dimenzija pokazuje koliko je agentu dopuštena interakcija s drugim dijelovima okoline. Isto tako pokazuje do koje razine on može samostalno djelovati;

inteligencija (eng. intelligence) – predstavlja dimenziju koja opisuje način na koji agent obrađuje informacije koje prima, odnosno do koje razine agent simulira inteligentno ponašanje. Dimenzija inteligencije se kreće od mogućnosti razumijevanja preferencija korisnika do mogućnosti zaključivanja, planiranja, i na kraju mogućnosti učenja, koja predstavlja zadnji stadij domene inteligencije;

mobilnost (eng. mobility) – povezana je s dimenzijom predstavništva jer određuje „kretanje“ agenta unutar okoline. Ova dimenzija se kreće od statičnog agenta do potpuno mobilnog agenta. Mobilnost je uvijek karakteristika agenta, ali o ovoj dimenziji ovisi koliko će agenti moći prebacivati svoj kôd unutar mreže(okoline).

Radi prikaza razlike između tradicionalnog softvera i softverskog agenta, stvorena je sljedeća tablica koja kroz veliki broj karakteristika prikazuje glavne razlike.

¹⁸ ibidem, str. 712

Tablica 2: Usporedba ostalih softvera i agenta

Karakteristike	Ostali softver	Agent
Priroda	Statičan	Dinamičan
Fokus	Izvršavanje akcije; rješenja stvorenog od strane programera koje je analizirao problem.	Rad s ciljem; važno je ono što se treba postići, a ne kako.
Manipulacija	Direktna: korisnik inicira svaku akciju.	Indirektna: autonomna.
Interakcija	Neinteraktivno.	Dijalog je u potpunosti interaktivan. Akcije mogu biti inicirane od strane korisnika ili agenta. Interakcija nije samo s korisnikom nego i drugim agentima.
Fleksibilnost	Nikad se ne mijenja, osim promjene od strane čovjeka ili greške u programu.	Adaptivan, uči.
Privremena kontinuiranost	Radi samo kada ga se potakne na rad od strane korisnika ili drugog programa.	Kontinuiran, radi prema potrebi.
Reakcije	Predvidive; radi ono što mu je rečeno čak i ako instrukcije nisu u skladu s ciljem.	Radi interpretiranje onoga što korisnik želi, a ne što kaže. U najboljim okolnostima, akcije su baziranje na pravilima, ali mogu se promijeniti u skladu s promjenom okolnosti.
Autonomija	Prati instrukcije.	Može inicirati akciju i reagirati na instrukcije.
Mobilnost	Ostaje na jednom mjestu.	Može biti mobilan putujući na druge servere.
Multitasking	Procese radi u već određenom serveru s ograničenom procesorskom snagom.	Šalje poruke kako bi obavio različite dijelove zadatka u isto vrijeme.
Lokalna interakcija	Mrežna tablica (eng. NTBL), pristupa podacima koristeći klijent-server arhitekturu.	Može putovati i komunicirati s različitim lokalnim entitetima, npr. baze podataka, drugi agenti.

Izvor : prilagođeno prema Efraim, T. Ramesh E, S. Dursun, D. , Business Intelligence and Analytics: Systems for Decision Support - 10th edition, Prentice Hall, New Jersey, 2010

Pregledom tablice lako je stvoriti mišljenje da su inteligentni agenti bolji od tradicionalnih softverskih rješenja. Upravo radi toga je napravljena tablica 2. Kroz usporedbu preko jedanaest kategorija, cilj je prikazati glavne razlike između agenta i ostalih softvera. Prva kategorija je jasan primjer. Priroda agenta je dinamična dok je ostali softver zamišljen kao statično rješenje. Dakle, priroda agenta je ekstremno drugačija u odnosu na ostala softverska rješenja. Agent djeluje i mijenja svoje postupke i akcije u odnosu na cilj i promjene u okolini. To je temelj njegove dinamične prirode. Ostala rješenja su statična i kao takva ne mogu prilagoditi svoje ponašanje u odnosu na promjene u okolini. Tu je prikazana glavna razlika, agent je zamišljen kao softversko rješenje za probleme dinamične okoline. Druge kategorije tablice 2 utvrđuju tu temeljnu razliku.

Funkcionalnost softverskog rješenja koje može samostalno obavljati svoj zadatak je velik korak naprijed u usporedbi s tradicionalnim softverom kojem treba direktna manipulacija korisnika. Zapravo, inteligentni agenti nisu univerzalno rješenje, nego softver koji je zamišljen kao odgovor na neke probleme s kojim se susreće informacijska tehnologija. Prvenstveno problem zatrpanosti informacijama. Danas i u budućnosti, u nekim situacijama će tradicionalni način programiranja softvera uvijek predstavljati bolju alternativu.

S aspekta pisanja samoga softvera, agent predstavlja puno veći izazov jer program koji je samostalan mora biti i kompleksan. Tako glavna prednost koda postaje njegova najveća mana. Od agenta se očekuje da može komunicirati na način da on sam može interpretirati želje korisnika, bez njene točne definicije. Kompleksnost takvoga softvera može predstavljati dvosjekli mač. Pogotovo u pitanju isplativosti i implementacije. Testiranje takvoga rješenja zahtijeva stavljanje agenta u okolinu i rigorozno testiranje svake njegove akcije. Cilj objektnog programiranja je stvaranje programskog koda koji je modularan. Ta karakteristika predstavlja programski kod koji se lakše i brže modificira. U nastavku ćemo se upoznati i s programskom arhitekturom inteligentnog agenta. S implementacijom takvoga softvera javljaju se i pravna pitanja, odnosno pitanje odgovornosti. Ako agent napravi akciju u ime svog korisnika, a ta akcija ima negativne posljedice, tko je odgovoran?

4.2 Pravno pitanje inteligentnih agenata

U članku Samira Choprae „Rights for Autonomous Artificial Agents?“ postavljeno je pitanje autonomnosti agenata. „Jim Cunningham je prikazao da postoji određena autonomija u svim programima, uzimajući u obzir web-servere ili e-mail daemon kao primjer. Tako se o inteligentnim agentima može razmišljati kao kretnji prema jednom kraju spektra autonomije.“¹⁹. Zbog kompleksnosti agenta, današnjih i budućih, ide se prema kraju spektra i pitanju kako tretirati agente kao entitete. Naravno ovo pitanje nije sada aktualno u tolikoj razini, ali u budućnosti će inteligentni softver biti u svakom aspektu života. Tako će rješavanje pravnog pitanja inteligentnih softvera u budućnost imati veliki utjecaj na svakodnevni život i poslovanje. Najbliži entitet agentu u pravnom sustavu su pravne osobe, poduzeća, koja se pravno tretiraju kao osobe, ali to zapravo nisu. U narednim primjerima je pokazana važnost pravnog pitanja agenata.

Temelj poslovanja unutar pravnog sustava jest ugovorno pravo. Jednostavno rečeno, ugovor jest sporazum između dvaju ili više stranaka oko određene stvari, usluge ili akcije. Ugovor mora biti jasan u tom smislu da se sve stranke moraju složiti, odnosno dogovoriti oko njegovih stavki. Sve stranke moraju biti obaviještajne oko svih stavki. Svi moraju biti informirani, i ne samo to, moraju biti u stanju razumjeti ugovor. Ugovor koji sadrži nejasnu komunikaciju je sam po sebi ništavan. Isto tako ugovor mora biti u skladu sa zakonima i ustavom države. Zadnji temelj ugovornog prava prije nego što je pravno vezujući je da niti jedna stranka nije pod bilo kakvim oblikom prisile. Ugovor dobiven pod prisilom je ništavan. Sada sa znanim temeljima ugovornog prava, prezentira se sljedeće pitanje. Postoji li stvarna potreba da agenti sklapaju ugovore? Zasada ne, jer agenti nisu uključeni u toliko pravno kompleksne akcije da bi opravdali potrebu za uređenim pravim pitanjem, odnosno da postoje u pravnom smislu. Ali to ne znači da se ova potreba neće pojaviti u bliskoj budućnosti.

Agenti, prvenstveno oni koji će primjenu imati u poduzećima, moraju imati jasno definirano pravno pitanje. Rješenje može biti takvo da određenim agentima damo status pravne osobe. Zašto? Zato što već postoji pravni okvir. Pravne osobe u pravu postoje još od 13. stoljeća. Unutar zakona o pravnim osobama jasno je definirano kako pravne osobe mogu formirati ugovore. Pitanje agenta se može riješiti tako da unutar okvira pravnih osoba uključimo inteligentni softver kao ekstenziju drugih fizičkih ili pravih osoba. Agenti trebaju

¹⁹ Samir Chopra., Rights for Autonomous Artificial Agents, Communications of the ACM, 2010., vol. 53. Br. 8, str. 38


biti uključeni u pravni sustav jer to predstavlja jedini način da se korisnici (fizičke i pravne osobe) zaštite od mogućih pravnih posljedica njihovih akcija.

4.3 Utjecaj korištenja inteligentnih softverskih agenata

Korištenjem softverskih agenata mijenja se način komunikacije s informacijskom tehnologijom. Internet, koji je postao javno dostupan u kasnim osamdesetima i devedesetima, je postao dio ljudskog života za veći dio razvijenog svijeta. Njegov utjecaj na ekonomiju, društvo, komunikaciju nije samo evidentan, on je očit. Internet je, od dana njegovog začetka pa do danas, prešao od znanstvenog eksperimenta do osnovnog alata za dobivanje informacija. Isto tako, korištenje agenta ima svoje ekonomske, organizacijske i socijalne posljedice. Takav uzročno posljedični efekt može se jednostavno objasniti rečenicom: „Kako mi mijenjamo tehnologiju, tako i ona mijenja nas“.

U ovom poglavlju su prikazane posljedice implementacije agenata i utjecaj njihov utjecaj na život ljudi, prvenstveno u poslovanju. Agent kao softver jednim dijelom pripada domeni umjetne inteligencije i kao takav će uzrokovati velike promjene u ponašanju svoga korisnika. Neki akademici iz tog razloga žele uvesti skup pravila i propisa u domenu agenata. To bi predstavljao korak u definiranju što je, a što nije agent. Glavni problem pri korištenju agenata s poslovne strane je pitanje povjerenja. Povjerenje, u poslovnoj i osobnoj interakciji predstavlja temelj svake interakcije. Agent bi onda u poslovanju imao ulogu virtualne osobe od povjerenja. On, za razliku od svih ostalih softvera, zahtijeva veliki stupanj povjerenja u njegove odluke i savjete, puno više od svih ostalih softvera do sada. Ipak, od agenata se očekuje puno više od bilo kojega softvera do sada. Kod implementacije softvera morat će se napraviti sustavno rješenje za pitanje povjerenja. Odgovor na pitanje povjerenja bi mogao biti certificiranje. Agent bi prije puštanja na tržište morao proći proces testiranja od strane neovisne organizacije kako bi budući korisnici bili zaštićeni od zlouporabe.

Slika 4: Učinci inteligentnih agenata unutar organizacijskih, socijalnih i tehnoloških okvira



Izvor : Alexander S., Umar Ri., Mihail C., *Unplanned effects of intelligent agents on Internet use: a social informatics approach*, *AI & Soc*, 2007., br. 21, str. 147

U radu akademika²⁰ predstavljaju se mogući utjecaji agenata na društvo u tri glavne kategorije. Te promjene su prikazane i vizualno na slici 4. One se dijele na kulturne, socijalne i organizacijske učinke. Slika prikazuje i podjelu tehničkih funkcija na trgovinske i informatičke zadatke. Ona je proizvoljna i služi samo za generalnu podjelu zadataka u poslovanju. Zanimljiv dio je podjela posljedica na ekonomske, političke i socijalne. Jedna ili više posljedica može biti dio istog učinka. No društveni utjecaj agenta ne predstavlja fokus ovoga rada pa su samo spomenute promjene koje agenti unose u društveno pitanje:

- 1) **pitanje privatnosti** – uvijek aktualno pitanje kod agenta koje dobiva novi kontekst. Koliko bi agenti trebali znati o nama. Odnosno, koliko bi te informacije koje smatramo privatnima, agenti mogli dijeliti u interakciji s drugim softverom;
- 2) **erozija vještina** – pojavom agenata doći će do određenih promjena na tržištu rada. Agenti će polako preuzimati poslove dana-mining-a i slično. Ali moguća primjena agenata je puno šira od same domene informacijske tehnologije;
- 3) **pitanje povjerenja** – od agenta se očekuje obavljanje aktivnosti u ime svoga korisnika. Agent te aktivnosti obavlja sam pa je evidentno pitanje povjerenja;

²⁰ Alexander, S. Umar, Ri. Mihail, C. *Unplanned effects of intelligent agents on Internet use: a social informatics approach*, *AI & Soc*, 2007., br. 21, str. 150

- 4) **socijalna otuđenost** – pojavom sve složenijih agenata ljudi će se sve manje oslanjati na ljudsku interakciju kao izvor korisnih informacija.

Usljed društvenih promjena koje će pokrenuti široka primjena agenata, dogodit će se i određene organizacijske promjene u poslovanju tvrtki:

transformacija e-poslovanja – prva organizacijska promjena je velika promjena u načinu kako će kupci tražiti i nalaziti proizvode na internetu. Asimetrija informacija, pojava prisutna na svakom tržištu, će uz rad agenata biti drastično smanjena jer će informacija o određenom proizvodu biti obrađena od strane objektivne strane (agenta). Budući kupci će imati veću informiranost o određenom proizvodu bez samostalnog prikupljanja informacija. Takva veća razina informiranosti će imati za posljedicu da će e-tržišta ići korak dalje prema potpuno konkurentnom tržištu, odnosno savršenoj konkurenciji. Povećanje u brzini pretraživanja dovest će do točke da definiranje želja korisnika traje duže nego njegovo pronalaženje. Cijena, koji je u većini slučajeva određujući faktor u kupovini, će pasti kao posljedica uvođenja agenata. Razni proizvođači će morati ujednačiti svoje cijene s konkurentima (pritom se misli na najjeftinijeg konkurenta) ili riskirati otuđivanje svojih kupaca. Ovo su samo od nekih mogućih promjena na tržištu. Jedna stvar je jasna, pozitivno ili negativno, agenti će unijeti drastične promjene u e-poslovanju;

promjena operativnog tereta – agenti organizacijama daju mogućnost da efikasno i brzo manipuliraju dostupnim informacijama. Kako bi se agentima omogućio rad, u poduzećima će morati doći do promjene organizacije rada. Primjer toga je da će se posao administratora baza podataka ustupiti inteligentnom agentu. No, u nekim slučajevima, neke poslovne funkcije će se ugasiti, a druge stvoriti. Posao traženja i provjere informacija će raditi agenti, dok će administrator obavljati kontrolu njihovog rada. Tako će i način komunikacije s vanjskim strankama doživjeti transformaciju. Organizacije će moći pružati svoje usluge doslovno dvadeset četiri sata dnevno. Svaka implementacija nove tehnologije zahtijeva od organizacija promjene u načinu poslovanja. U slučaju agenata te promjene će zahtijevati velike pomake u organizaciji jer se radi o drastičnoj promjeni u načinu poslovanja. Način na koji će organizacije pristupiti implementaciji agenata odredit će hoće li ova tehnologija imati pozitivan ili negativan rezultat;

sigurnosno opterećenje – agenti predstavljaju veliku razinu autonomije i kompleksnosti softvera. Implementacijom se postavljaju nova pitanja u području sigurnosti informacija i povjerenja. Sadašnji sigurnosni okviri nisu dovoljni da jasno definiraju sigurnosne mjere i potrebna je nova politika kada su agenti u pitanju. Morat će se uspostaviti

propisani protokoli komunikacije između agenata. Je li smisleno da agenti sami procjenjuju komunikacijske situacije ili će agent pri svakoj instanci nove komunikacije s trećom stranom morati pitati korisnika. U slučaju da pri svakoj instanci agent traži korisnikovu odluku, sigurnosni problem će biti lako riješen jer će korisnik odgovarati za svoju odluku. Ali u slučaju poslovne organizacije u kojoj u bilo kojemu trenutku organizacija ima desetke raznih agenata koji obavljaju svaki zasebnu funkciju, može doći do sigurnosnih problema. Pri tome se misli na pitanje sigurnosnog opterećenja. Uvođenje agenata u poslovanje će potencijalno dovesti do nove razine opterećenja sigurnosnih sustava poslovnih organizacija. Jedino će pravilna implementacija novih sigurnosnih mjera moći otkloniti mogućnost zlouporabe agenata.

5. Semantički web - uvod u strukturu agenata

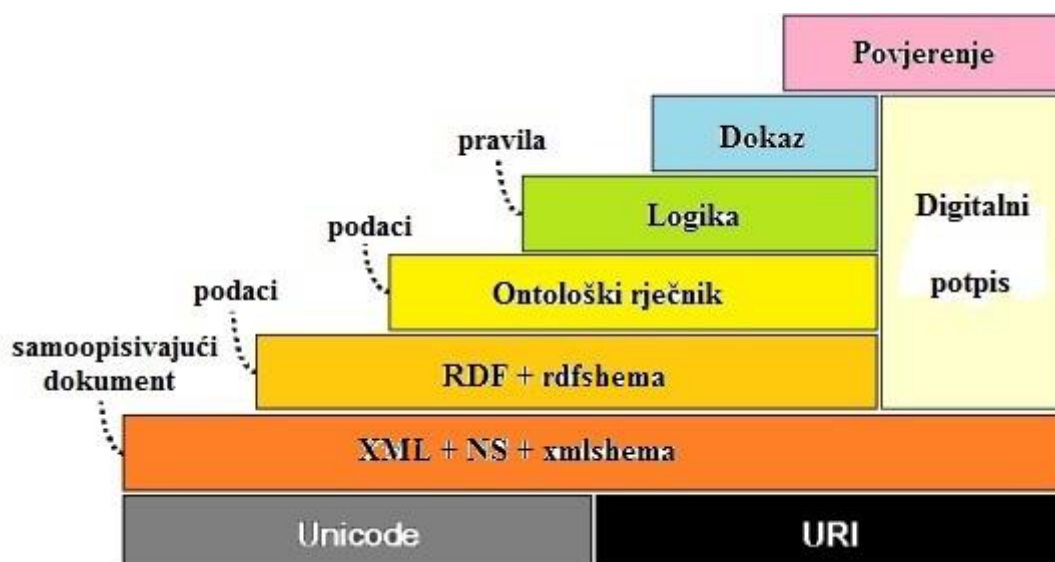
Prije nego se u radu objasni anatomija agenta, mora se osvrnuti na koncept i pojavu semantičkog web-a. U tom duhu se javlja pitanje što je semantički web i zašto je važan za prošle, sadašnje i buduće poslovne agente. Web-aplikacije i stranice koriste veoma jednostavan način komuniciranja s drugim softverima. Naravno, pričamo o HTML (hyper text markup language), tradicionalnom i za sada prevladavajućem načinu pisanja web-stranica. Jednostavno rečeno, on je „...dizajniran za ljude i baziran na konceptu da se informacije sastoje od stranica teksta i grafike koje sadrže linkove. HTML izvršava snažnu kontrolu nad izgledom web-stranice.“²¹ Napisan je tako da čovjek može logički precipirati podatke koji se nalaze u njemu. Kada ostali softveri komuniciraju s njime, nailaze na određenu prepreku koja je posljedica ograničenosti jezika. Unutar njega ne postoji mogućnost iskazivanja apstraktnih stvari poput koncepata ili međuveza između grupa podataka. Dakle, postoji nemogućnost jezika da efikasno predstavi i definira veze između raznih skupina podataka. Jednostavno rečeno, nema načina kojim bi se pokazala definicija i kontekst podataka koji su upisani. Ili još zabrinjavajuće, zbog takvih ograničenja agenti neće moći doći do određenih podataka u prikladnom obliku. Agenti su softverska rješenja namijenjena za samostalno izvršavanje korisnikovih ciljeva. Više od toga, sposobni su raditi s veoma kompleksnim međuvezama i definicijama informacija koje percipiraju. Kako bi efikasno obavljali raznolike zadatke, trebaju kvalitetan način komunikacije s web-stranicama.

²¹ Efraim, T. Ramesh E, S. and Dursun, D. *op. cit.*, str. 725

Srž problema je prikazan na sljedećem primjeru. Recimo da je agent angažiran rezervirati karte za avion na relaciji Pula-Moskva koji polijeće za dva dana. Dan je dodatni zahtjev koji ograničava da ta karta bude najjeftinija moguća. Vrijeme leta mora biti nakon 12 sati. Nakon što pronade stranice većih aviokompanija, fiktivni agent će naići na problem. Arhitektura HTML-a mu neće dopustiti uvid u raspored letova, osim ako ima autorizaciju kojom može stvoriti upit unutar baze podatka iste kompanije. Zašto? HTML je jezik koji tumači kako je napravljena vizualna struktura stranice, odnosno kako stranica izgleda. Izgled je nešto što percipira korisnik, odnosno čovjek, za kojeg je HTML prvenstveno i napravljen. Ali „Agenti ne mare za izgled stranice, oni se bave njezinim sadržajem.“²²

Semantički web je novi način gledanja na arhitekturu web-stranica. On je prvenstveno pokret od strane W3C-a (World Wide Web Consortium) koji želi transformaciju interneta. Želi da se internet od svoje semi-strukturne konstrukcije dokumenata, okrene prema stvarnom „web-u podatka“. Za agente koji će naseljavati takav web, on predstavlja način demonstracije agentove moći. Koncept i pojava semantičkog web-a je usko povezana s Webom 3.0. Sadašnja interakcija web-a se smatra interakcijom na razini inačice 2.0. Pritom se misli na transformaciju interneta putem raznih socijalnih i drugih servisa za izmjenu audiovizualnih podataka (npr. Facebook, Youtube). Na slici 5 se vidi slojevita arhitektura koja omogućava transformaciju u Web 3.0.

Slika 5: WEB 3.0 slojevi



Izvor: <http://www.w3.org/2001/12/semweb-fin/w3csw> , uzeto 30.9.2014

²² *ibidem*, str. 726

Na slici 4 su komponente koje tvore semantički web. Gledajući od dolje prema gore, komponente su:

1. **Unicode** – računalno-industrijski standard koji se koristi za konzistentno enkodiranje, prikazivanje i upravljanje jezikom;
2. **URI (eng. Uniform Resource Identifier)** – obavlja sličnu funkciju kao postojeći URL-i (eng. Uniform Resource Locator), ali s generaliziranim pristupom. URL-i su vezani za jednu stranicu, a URI-i za sve web-resurse. Ti resursi se mogu proširiti tako da obuhvaćaju objekte koji se ne nalaze na internetu. Tako se dolazi do tvrdnje da je svaki URL ujedno i URI, ali obrnuto ne vrijedi;
3. **XML + NS + xmlschema** – ekstenzija HTML-a. Na postojeću strukturu mogu se vezati definicije koncepata kroz oznake (eng. tags). Te oznake stvara korisnik. XML predstavlja temelj semantičkog web-a i web-servisa. Daje mogućnost vezivanja semantičkih informacija na HTML strukturu;
4. **RDF + rdfschema (eng. Resource Description Framework)** – stvoren radi povezivanja raznih URI-a. Daje podatkovni model koji uključuje brzu integraciju izvora podataka kroz vrstu premošćivanja semantičkih razlika. Jednostavno rečeno, on je skup izjava o određenom resursu i njegovim vezama;
5. **ontologijski rječnik (eng. Ontology vocabulary)** – ontologija je znanost o postojanju (pritom se misli da npr. čovjek postoji kao biće). Ona se ovdje koristi u domeni umjetne inteligencije, prvenstveno za konceptualizaciju. U tom sloju se definira znanje, domena, vezani termini, semantičke veze i logika. Recimo, ontologija auta uključuje motor s unutrašnjih sagorijevanjem, konstrukciju, metalurgiju te međusobne razlike između auta. U strukturi semantičkog web-a, ovaj sloj je kolekcija RDF (eng. Resource Description Framework) izjava o odnosima između podataka i načinima za stvaranje logičkih inferenci;
6. **logika (eng. Logic)** – sadrži logičke izjave vezane za servise semantičkog web-a. Služi kao skup pravila po kojima se izvršava logika ontološkog sloja te kao način kontrole;
7. **dokaz (eng. Proof)** – sadrži skup funkcija prema kojima razni softveri, pri tome se misli na agente, mogu „uvjeriti“ u istinitost tvrdnji i koncepata koje nalaze u prijašnjim slojevima. Sloj je sigurnosne prirode i služi kao temelj za komunikaciju agenata na semantičkom web-u;

8. **digitalni potpis (eng. Digital signature)** – služi kao postojeće sredstvo dokazivanja i utvrđivanja identiteta određenog softvera, podatka ili dokumenata. Usko je povezan sa slojem dokaza;
9. **povjerenje (eng. Trust)** – najviši je stupanj semantičkog web-a. Postiže se jedino ako su ispunjeni uvjeti svih prijašnjih slojeva. Ovdje se misli na povjerenje u najširem konceptu. Uključuje povjerenje između agenata, prezentiranih podataka i korisnika.

Njegova arhitektura je podijeljenija na dva dijela. Slojevi od jedan do četiri predstavljaju isključivo strojne dijelove te služe samo za prikazivanje podataka i njihovih veza. Taj sloj će određivati kako će računalo percipirati podatke koje nalazi. Sljedeći slojevi predstavljaju mehanizme po kojima će se odvijati komunikacija između agenata.

Takav način strukture podataka je lako razumljiv jer uključuje grafičke prikaze veza između podataka. Resursi se mogu lakše priključiti u sustave koji koriste taj pristup. Štedi se na vremenu za razvoj i smanjuje trošak jer su resursi lakše dostupni i međusobno povezani. Ažuriranje je olakšano jer agenti mogu automatski dodavati novije informacije vezane za resurse i podatke. Ovaj proces može potencijalno razviti veću razinu inteligencije agenata. Zbog velike međupovezanosti svaki pojedinačni resurs se može iznova ponovno koristiti.

Semantički web ima svoje mane. Grafički prikazi mogu biti previše jednostavni, zanemarujući određene veze između podataka. Onkologija može biti krivo definirana. Trebaju se stvoriti bolji alati za pretraživanje takvog web-a. I najveća mana s poslovne strane, zbog velike međupovezanosti postoji realna mogućnost zlouporabe i sigurnosnog rizika. S obzirom na sve mane i prednosti može se reći da su inteligentni poslovni agenti i semantički web dvije strane iste stvari jer se međusobno unaprjeđuju.

6. Struktura inteligentnih agenata

Agent je u radu promatran kao apstraktni pojam s navedenim važnim komponentama i uporabom. Sada se prelazi na moguće načine stvaranja inteligentnih agenata. Prelazi se s promatranja agenta kao koncepta na praktičan dio kreiranja istoga. Agent, kao i čovjek, ima svoju anatomiju, odnosno strukturu, koja mora biti jasno definirana. U prijašnjem poglavlju agent je definiran kao softver koji radi na interaktivnom principu, prati i reagira na svoju okolinu. Postupak je sljedeći, agent percipira okolinu, donosi zaključke o okolinu kroz

perspektivu cilja, bira akciju koja je primjerena za percipirano stanje u okolini i cilj. Na kraju napravi akciju.

Prije nastavka se mora spomenuti jedan znanstveni princip, racionalnost. Racionalnost je princip koji ima svoju primjenu u ekonomiji, sociologiji, psihologiji, političkim znanostima, filozofiji i evolucijskoj biologiji. Primjerice, čovjek se kao biće smatra racionalnim, radi akcije zasnovane na logičkom razmišljanju o dostupnim činjenicama s ciljem optimizacije svojih želja i potreba. Koliko je važan ovaj princip govori činjenica da ekonomska teorija smatra racionalnost jednim od svojih temelja. Implicitno se pretpostavlja da svaki ekonomski sudionik operira na principu racionalnosti. Bez ove pretpostavke nemoguće je analizirati i uspostaviti i najjednostavnije ekonomske koncepte i teorije. Racionalnost je važna za koncept i pojavu inteligentnog poslovnog agenta. Na kraju krajeva, poslovanje spada u ekonomsku domenu ljudske aktivnosti. Gotovo svatko zna što je racionalni čovjek, no kakva treba biti definicija racionalnog agenta?

U knjizi „Artificial intelligence modern approach“²³ smatra se da racionalnost agenta ovisi o četiri stvari:

- 1. mjera performansi koja definira kriterije uspjeha,**
- 2. agentovo dosadašnje znanje o okolini,**
- 3. akcije koje agent može poduzeti,**
- 4. agentova dosadašnja percepcija.**

Gledajući ove četiri stvari može se reći: „Za svaku moguću situaciju u okolini racionalni agent treba selektirati akciju za koju se očekuje da maksimizira svoju mjeru performansi, i to na osnovu dokaza dobivenih promatranjem okoline te bilo kojeg znanja koje agent ima.“²⁴. Moram spomenuti da princip racionalnosti ne mora biti primijenjen pri izgradnji agenta, ali uključivanje ovakvog koncepta pokazuje određene prednosti.

Prva je da racionalni pristup pri programiranju od agenta ne zahtijeva posjedovanje znanja o posljedicama svoje akcije. Taj princip je pri izgradnji sasvim nepotreban. Agent se može generirati tako da bude čisto reaktivan, odnosno kada je situacija x (sX) prisutna u okolini, izvrši akciju x (aX). Taj savršeni slučaj ne postoji u prirodi koja nas okružuje. Ljudsko znanje je fragmentirano i nedovršeno kada je u pitanju okolina. Racionalni pristup počiva na ideji da se unutar agenta usadi skup pravila, odnosno vrsta kompasa koji će omogućiti da cilj bude ispunjen na optimalan način. Tako će se agent i u nepredvidivoj okolini moći orijentirati i procijeniti što je moguće napraviti u skladu s ciljem.

²³ Stuart, R. Peter, N. *op. cit.*, str. 36

²⁴ *ibidem*, str. 37

Sve što je rečeno o racionalnosti se može jednostavno prikazati na ovoj hipotetskoj situaciji. Napravljena su dva agenta za dva usisivača, nazovimo ih RU (racionalni usisivač) i IU (iracionalni usisivač). Ti usisivači kroz svoje senzore percipiraju samo dvije stvari: čisto i nije čisto. Ako okolina nije čista, usisivač će čistiti; ako je okolina čista, usisivač neće čistiti. Oba usisivača su dobro dizajnirana kao i agenti u njima tako da se odmah može reći da razlika nije u dizajnu. RI i IU će čistiti dok soba kroz senzore ne bude čista. Ali kada usisivači obave do kraju svoju funkciju, dogodi se veoma čudna stvar. RI se ugasi, ali IU nastavlja dalje skenirati sobu tražeći nečistoće. RI je racionalno programiran i kao takav kada percipira da je soba u cijelosti čista, isključuje se i čeka određeni period vremena da se ponovno aktivira i provjeri stanje sobe. IU zna kroz svoje perceptore da je soba čista, ali će svejedno kružiti po zamišljenoj sobi. RI i IU obavljaju svoj cilj, ali RI svoj rad obavlja prema racionalnom principu. IU, nakon što ispuni svoj cilj, nastavlja kružiti i tako troši energiju te si skraćuje životni vijek. Razlika u ova dva pristupa je samo u njihovoj racionalnosti. Agent koji ima koncept racionalnosti će, prema mišljenju ovog autora, imati skup pravila koji mu omogućavaju kvalitetnije orijentiranje i shvaćanje okoline. I indirektno, cjelovitije shvaćanje cilja. Ljudi u svojoj interakciji primijenjuju ovaj koncept, zašto bi agenti bili drugačiji?

6.1 Programiranje inteligentnih poslovnih agenata

Najjednostavniji način promatranja anatomije agenta je podjela na dvije komponente. Prva komponenta je arhitektura agenta koja je uvijek neka vrsta računalnog sustava. Ova komponenta sadržava fizičke dijelove agenta poput senzora, procesora itd. Druga komponenta je program, odnosno softverski kod. U jednostavnim terminima, anatomija agenta sastavljena je od arhitekture agenta (tijela) i programa agenta (mozga).


$$\text{ANATOMIJA AGENTA} = \text{ARHITEKTURA} + \text{PROGRAM}$$

Za tematiku rada pitanje arhitekture je nevažno. Važan je programski dio anatomije jer je vitalna komponenta za shvaćanje anatomije inteligentnih agenata. Program, odnosno softver je komponenta koja može biti napravljena na bilo koji način. Ipak, postoji podjela načina na koji mozak agenta može biti konstruiran. To su²⁵:

²⁵ *ibidem*, str. 49

jednostavni refleksni agenti (eng. simple reflex agents) – najjednostavnija vrsta agenata. Ova vrsta bira svoje akcije samo na temelju trenutne percepcije okoline. Agent ove vrste sastoji se od skupa refleksnih akcija. Radi po principu uvjet-akcija. Princip refleksne akcije je prisutan kod svih bića, biologija je prepuna takvih primjera. Kod izrade se prvo napravi vrsta generalnog prevoditelja koji će se sastojati od skupa svih pravila nužnih za tog agenta. Za svaku željenu akciju se postavljaju uvjeti koji trebaju biti prisutni u okolini kako bi se željena akcija ostvarila. Slika 6 prikazuje taj princip. Izgled programa je vidljiv na slici 7. Naravno, prikazana arhitektura je čisto konceptualna i varirat će od programa do programa.

Slika 6: Model refleksnog agenta



Izvor : Stuart, R. Peter, N. , Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

Slika 7: Funkcija refleksnog agenta

```

function SIMPLE-REFLEX-AGENT(percept) returns action
  static: rules, a set of condition-action rules

  state ← INTERPRET-INPUT(percept)
  rule ← RULE-MATCH(state, rules)
  action ← RULE-ACTION(rule)
  return action
  
```

Izvor : Stuart, R. Peter, N. , Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

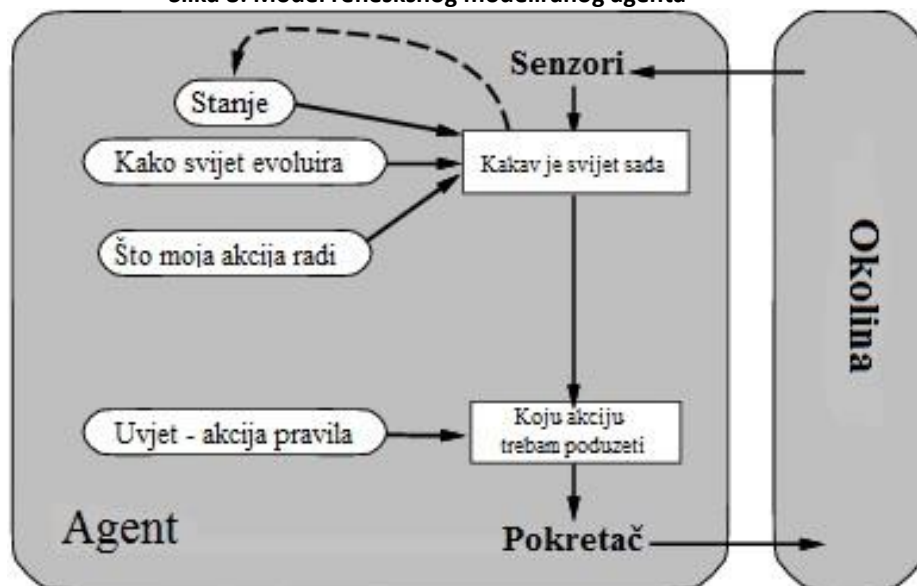
Program je dosta jednostavan. Prevodilac (na slici eng. Interpret - Input) generira neku vrstu apstraktnog opisa okoline, kao što je spomenuto prije, to je trenutno stanje okoline. Senzori su oni koji percipiraju trenutno stanje. Oni daju odgovor na pitanje **kako svijet izgleda u ovom trenutku?** Program pretražuje onda pravilo koje odgovara trenutnom stanju okoline. Pitanje **koju akciju poduzeti** započinje proces. Pravilo mora odgovarati stanju okoline i biti unutar **uvjet-akcija pravila**. Kada je pravilo nađeno, agent izvršava akciju. Ona je izvršena kroz **djelovatelje**. Isti postupak prisutan je i na slici 7. Logički početak rada funkcije je stanje (eng state.) koje je ovisno o inputima, odnosno percepciji (eng. percept) agenta. Uvjet-pravila (eng. rule) su sljedeći dio i ovise o stanju te pravilima (eng. state, rules). Ovo je faza agenta u kojoj traži odgovarajuće pravilo za stanje u okolini. Funkcija završava s odgovarajućom akcijom (eng. action) koja se vraća kao rezultat funkcije. Prednost ovakve vrsta programa je u elegantnoj jednostavnosti. Ali, refleksno kondicioniranje akcije nije primjer inteligencije. „Agent radi samo ako se pravilna odluka može izvršiti na temelju trenutne percepcije okoline, i samo ako okolina može biti percipirana u cijelosti.“²⁶. Citat prikazuje glavni problem, agent mora imati cjelokupnu percepciju okoline što u većini slučajeva nije moguće. Drugi problem je što ova vrsta program nema sposobnost učenja. Program također ima opasnost stvaranja neprekidne petlje jer je u tolikoj mjeri ovisan o skupu pravila koja su mu dana. Opasnost se može prekinuti ugradnjom neke mjere randomizacije. Recimo, kod prijašnjeg primjera usisivač randomizirano bira putanju čišćenja soba. Ova vrsta agenta ima svoje mjesto u poslovanju, ali nije primjer inteligentnog poslovnog agenta;

modelirani refleksni agenti (eng. model-based reflex agents) – akcije su implementirane u nekom obliku direktnog mapiranja od situacije do akcije. Agent ima strukturu koja mu omogućava praćenje stanja u okolini, čak i kad se dio okoline ne može trenutno percipirati. Ovime se rješava problem refleksnog agenta tako što pohrani podatke o dijelu okolne koje ne može trenutno percipirati. Korak naprijed se ostvaruje tako da isprogramirani agent sadrži dvije vrste znanja. Prvo znanje daje informacije o tome kako se okolina mijenja neovisno o agentu. Drugo znanje su akcije agenta i utjecaj akcija na okolinu. Ova znanja daju agentu takozvano znanje „o tome kako okolina djeluje“. Ova kombinacija daje agentu model njegove okoline. Zato se zove modelirani refleksni agent. Program, za razliku od čisto refleksnog, može imati

²⁶ *ibidem*, str. 49

unutar sebe znanje o prošloj situaciji okoline. Agent je sposoban reagirati čak i kada nema savršeno znanje o okolini. Slika 8 prikazuje konceptualni rad agenta. U odnosu na sliku rada refleksnog agenta, javljaju se tri nova elementa. Ove se promjene u konceptualnom prikazu agenta javljaju na strani senzora, odnosno percepcije okoline. Tri nova elementa: **stanje**, **kako svijet evolvir**a i **što moja akcija radi**. Element **Stanje** daje trenutno stanje u okolini. Element **kako svijet evolvir**a je mogućnost percepcije prošlih stanja u okolini. Element **što radi moja akcija** je dodana funkcionalnost praćenja promjena u okolini, uzrokovanih od agenta. Promjene na programskom prikazu su dodatak određenom modelu agenta i rezultat su promjene stanja u okolini te skupa mogućih akcija agenta. Unutar funkcije stanje (eng. state) promijenjen je broj prisutnih varijabli, što je vidljivo na slici 9. Taj agent se sastoji od: modela (eng. model), stanja (eng. state), akcije (eng action) i prijašnjih prisutnih percepcija (eng. percep). Akcije su prisutne u stanju kao posljedica druge promjene. Promjena je dodatak modela unutar funkcije i time akcije postaju važne za stanje jer ih agent može percipirati kroz vrijeme. Okolina unutar agenta je podijeljena na dva dijela. Prvi je stanje (eng. state), što je prikaz trenutnog stanja u okolini. Drugi dio je model, odnosno aproksimacija budućeg stanja okoline. Važno je zapamtiti kako je model samo aproksimacija trenutnog stanja u okolini i kao takav ne zahtijeva savršenu preciznost. Model mora biti dovoljno strukturiran da omogući agentu pravilno donošenje akcija.

Slika 8: Model refleksnog modeliranog agenta



Izvor: Stuart, R. Peter, N. , Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

Slika 9: Funkcija refleksnog modeliranog agenta

```
function MODEL-BASED-REFLEX-AGENT(percept) returns an action
  persistent state, the agent's current conception of the world state
             model, a description of how the next state depends on current state and action
             rules, a set of condition—action rules
             action, the most recent action, initially none

  state ← UPDATE-STATE(state, action, percept, model)
  rule ← RULE MATCH(state, rules)
  action ← rule.ACTION
  return action
```

Figure 2.12 A model-based reflex agent. It keeps track of the current state of the world, using an internal model. It then chooses an action in the same way as the reflex agent.


Izvor : Stuart, R. Peter, N. , Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

ciljno bazirani agenti (eng. goal-based agents) – akcije se izvršavaju na osnovu manipulacije strukturama podataka predstavljajući vjerovanja, želje i namjere agenta. Za razliku od prijašnjih vrsta, ovakvi agenti svoje akcije podređuju isprogramiranom cilju. Ako su ciljno bazirani agenti sljedeći korak prema inteligentnim agentima, onda je lako primijetiti doprinos ovih agenata. Taj korak ispred je cilj. Ciljani agenti imaju svoj predefiniрани cilj. Ljudi u svojim akcijama uvijek imaju princip rada podređen cilju. Sinonim za te ciljeve su snovi, želje i potrebe. Razuman čovjek uvijek može svoje akcije podrediti cilju. Ovaj agent emitira tu karakteristiku ljudske inteligencije. Dodavanje dimenzije cilja daje agentu način biranja akcija između onih koje su poželjne i raspoznava neželjene akcije. Na slici 10 vidimo kako je skup uvjeta-pravila zamjenjen ciljevima. Kada se ova dimenzija priključi drugim dimenzijama, poput okoline i modela, agentu je dana vrsta unutarnjeg kompasa. Agent sada zna gdje je, gdje treba ići i kako doći do mjesta unutar svoje okoline. Nakon toga dolazi do uključivanja budućnosti kao koncepta. Agent si sada postavlja dva nova pitanja: „Što će se dogoditi ako se napravi ova akcija?“²⁷ i „Što će me usrećiti?“²⁸. Promjena je jasno vidljiva na Slici 10.

²⁷ *ibidem*, str.51

²⁸ *ibidem*, str. 53

Slika 10: Model ciljno baziranog agenta




Izvor: Stuart, R. Peter, N. , Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

Informacije su u ovome agentu prikazane eksplicitno za razliku od prijašnjeg refleksnog agenta gdje informacija prolazi kroz skup predodređenih pravilo-akcija klauzula. Program sada ima karakteristiku fleksibilnosti tako da može modificirati svoje akcije u odnosu na cilj. Promjena je primjetna i na slici. Agent može modificirati svoje akcije kako bi ostvarivao cilj bez obzira na promjene u svojoj okolini. Više od toga, prednost ovakvih agenta leži u činjenici da s lakoćom mogu promijeniti i cilj. Refleksni agent bi pri takvoj promjeni trebao zamijeniti sve prijašnje pravilo-akcija klauzule. Jednostavno rečeno, agent može učiti na svojim akcijama, odnosno ima mogućnost učenja;

korisno-bazirani agenti (eng. utility-based agents) – ovi agenti su korak dalje od ciljnih. Pored isprogramiranog cilja agentu je izgrađena neka vrsta unutarnjeg mjerača. Agent sada neće birati samo akciju koja ispunjava svoj cilj, nego će birati akciju koja to radi na optimalan način. Agent zna dva krajnja stanja u odnosu na cilj. Oni su „sretan“ i „nesretan“. U kompleksnoj okolini ovakva kruta definicija agentu nije dovoljna da ostvari poželjno ponašanje. Treba biti sposoban uspoređivati buduća stanja okoline i birati ono koje najbolje ispunjava cilj. Funkcija korisnosti agenta nije ništa nego internalizacija mjere performansi istog. Agent bira određenu akciju ako su funkcija korisnosti i mjera u skladu, odnosno kada se slažu. Tako dolazi do racionalnog načina biranja akcija. Postupak je vidljiv na konceptualnom modelu agenta (Slika 11). Velika promjena konceptualnog modela u odnosu ostale jest dodavanje **korisnosti** koja zamjenjuje ciljeve ili skup uvjeti-pravila. Za novi element

agenta je vezano pitanje **koliko ću biti sretan u tom stanju?** Odgovor na to pitanje je glavno mjerilo performansi agenta, odnosno uspjeha.

Slika 11: Korisno bazirani agent



Izvor : Stuart, R. Peter, N. , *Artificial intelligence-a modern approach*, Pearson Education Inc. , New Jersey, 2003.

Ovakav agent bira svoje akcije na: „maksimizaciji korisnosti moguće akcije, odnosno, na temelju korisnosti agent očekuje dobit, u odnosu na dane vjerojatnosti i korisnosti svakoga ishoda“²⁹. Polako se dolazi do inteligentnih agenata jer dobivaju sposobnost odabira optimalne akcije između skupa poželjnih akcija. Ova vrsta agenta u potpunosti ima razvijenu karakteristiku racionalnosti koja je temeljno povezana sa samom inteligencijom. Kako programskom tako i ljudskom.

Anatomiju takvog agenta čine program i njegova arhitektura. Prije je spomenuto kako je arhitektura nevažna za ovaj rad. Ali je program, odnosno način na koji agent pristupa problemu biranja akcije, važan. Način agentovog biranja akcije se može jasno definirati kao metoda ili tehnika koju agent koristiti kada selektira akciju. Spomenuti su pristupi poput fuzzy logike ili genetičkih algoritama, ali to su samo neki od raznih koji se primjenjuju. U nastavku će one detaljnije biti opisane s ciljem odgovaranja na tri jednostavna pitanja. Kako se rješava pitanje biranja akcije i po čemu se ova metoda razlikuje od ostalih? Koje su prednosti ove metode? Koje su mane ove metode? Mogu se shvatiti kao vrsta putokaza koji će ilustrirati kada je primjereno koristi jednu metodu, a ne drugu. One su:

²⁹ *ibidem*, str. 54

simbolički pristup – javlja se rano u povijesti umjetne inteligencije. Pristup smatra da agent odlučuje optimalno, kroz dokaziv plan koji kasnije izvršava. Plan mora biti dokaziv jer će agent odlučivati koja akcija je optimalna i to na temelju podražaja, informacija i dokaza koje daje okolina. Ključni koncept ovoga pristupa je hipoteza formalnog sistema, odnosno sistema fizičke simbolike. On smatra da se inteligencija može ostvariti preko programa s funkcijom interpretacije informacija iz okoline u simbole koji postavljaju fizičke obrasce u strukture, odnosno izraze. Agent onda manipulira izrazima i ako je potrebno stvara nove izraze. Ovaj pristup implicira da je i ljudsko razmišljanje neka vrsta manipulacije simbolima. Dakle, agent percipira određeni simbol. Onda procesuirá njegovo značenje, odnosno izraz, analizira ga u odnosu na cilj te napravi akciju. Da bi ovakav pristup uspio, moraju se obuhvatiti i opisati sve informacije koje dobivaju senzori, sve moguće akcije i cilj ili ciljevi unutar programa. Cijeli sustav je zasnovan na već definiranoj logici. Ciljno bazirani agenti, objašnjeni u prijašnjem tekstu su tipični primjer ovakvog pristupa. Velik broj agenata koristi ovaj pristup za određivanje svojih akcija. Razlog tome je jasan. Kad agent procesuirá određeni izraz, on samo zapravo izvršava akciju koja je unaprijed definirana u njegovom kodu. No ovaj pristup ima određene nedostatke. Prvi je da je u potpunosti ovisan o simbolici, odnosno rječniku izraza kroz koje percipira svoju okolinu. Ona je predefinirana i kao takva, ako je pogrešno postavljena ili nedovoljno definirana, dovest će do pogrešne akcije. Drugi nedostatak je što ovakav pristup, koji percipiranu okolinu pretvara u skup simbola, ne može realistično prikazati okolinu bez da je nepotrebno pojednostavljuje;

distribuirani pristup – pristup se može nazvati i decentralizirani pristup selektiranja akcija. Funkcije programa su decentralizirane u zasebne module. Konceptualni plan je da se akcije analiziraju kroz definirani broj modula. Svaki modul ima svoju specijalnost kroz koju analizira optimalnu akciju. Moduli funkcioniraju paralelno. Koherentna, odnosno optimalna akcija se javlja kroz konsenzus između modula. Za njezino stvaranje važni su moduli zaduženi za međusobno komuniciranje. Inspiracija za ovu vrstu pristupa je biološka arhitektura mozga. Neuronu su zapravo biološki moduli koji u svojoj međusobnoj komunikaciji i procesima tvore ljudsku inteligenciju. Ljudski mozak ima skupine neurona koje imaju predodređenu funkciju (centri za govor, sluh, logičko razmišljanje, jezik, memoriju...). Strukturu navedenih centara čine neuroni koji su međusobno povezani za određenu svrhu. Veoma su fleksibilni jer mogu stvarati i prekidati veze između sebe prema potrebi. Programski moduli su zamišljeni da rade na isti način. Kao što čovjek treba frontalni režanj, ovakav agent treba zapovjedni modul koji će koordinirati akcije svih modula te ostvarivati konsenzus. Najpoznatija tehnika ovog pristupa su neuronske mreže. Glavna mana

ovog pristupa je velika razina kompleksnosti. Moduli moraju biti tako programirani da međusobno komuniciraju i stvaraju konsenzus o percepciji okoline i o potrebnoj akciji što je velik programski problem. Kako ćemo konstruirati zapovjedni model koji mora upravljati s, recimo, petdeset zasebnih modula, svaki sa svojom funkcijom, odnosno specijalnošću. To je zahtjevan programerski zadatak i zato je rijetko korišten u poslovnim rješenjima;

dinamično planirani pristup – vezan je sa simboličnim pristupom jer uključuje definiranje, odnosno programiranje akcija. Ali u ovom pristupu program samo izvršava samo jednu akciju koja je rezultat predefiniranog programa i percepcije okoline. Agent percipira i odlučuje u instancama, odnosno sekvencama. Za razliku od simboličkog pristupa to mu omogućuje određenu fleksibilnost pri odlučivanju jer je sposoban prilagoditi se trenutnom stanju okoline. No postoji mogućnost za kombinatoričku eksploziju (funkcija koja doživi ekspanzionalni rast kao rezultat uključenih varijabli). Kompleksniji je od simboličkog pristupa, ali je jednostavniji od distribuiranog pristupa jer ne zahtijeva modularnu strukturu. Metoda konačnog stanja koristi se kod UI videoigara za percepciju, analizu i predviđanje akcija korisnika.

7. Analiza poslovnih aplikacija inteligentnih agentskih sustava

U ovom dijelu rada prikazana su tri sustava bazirana na radu agenta. Prije nego što su prikazani, mora se napomenuti gdje se sve u poslovanju koriste agenti. Jednostavan odgovor na pitanje je da se koriste u svakom aspektu poslovanja. Posljedica toga je da bilo koji softver može biti smatran agentom, uz određene uvjete. Postoje različite definicije agenta, no u kontrastu, karakteristike koje softver mora imati da bude smatran agentom su jasno definirane. Glavna od njih je mogućnost samostalnog rada bez korisnika, odnosno autonomija. Prisutni su u svim poslovnim funkcijama i domenama (teška industrija, turizam, telekomunikacije itd.). U praksi poslovanja poduzeća agenti gotovo nikada nisu samostalna softverska rješenja. Agent može biti dio višeagentnog sustava. Taj sustav sadrži veći broj agenata od kojih svaki obavlja svoju funkciju. Inteligentni agentski sustav može biti dodan u određeni ekspertni sustav ili bazu podataka ili neko treće softversko rješenje. Ambicija poduzeća je imati cijeli softver intrigiran u jednu cjelinu radi lakšeg korištenja istog. To u nekim slučajevima nije moguće zbog određenih prepreka, ali uvijek ostaje kao indirektni cilj. U ostvarivanju toga agenti mogu predstavljati veliki korak naprijed, ali samo ako se pravilno koriste.

U poslovanju nema inteligentnih poslovnih agenta, ali ima višeagentskih sustava ili barem sustava temeljenih na agentskom pristupu. Do sada u radu nije spomenuto kako izgleda praktično agentsko rješenje. Sada će to pitanje biti odgovoreno kroz tri primjera koja će prikazati kako se primjenjuju agenti u poslovanju. Za prvi primjer je iskorišten rad akademika X. N. Jianga i K. L. Yunga „A new intelligent system for senior executives to maintain remote control of their company“. Drugi se bavi efikasnijom organizacijom distribucijskog lanca u maloprodajnom poduzeću. Autori su Chieh Y. , Ruery-Shun C. , Chia-Chen C., a naslov „Intelligent service - integrated platform based on the RFID technology and software agent system.“. Treći primjer je implementacija agentskog pristupa e-usluga telekomunikacijskog poduzeća. Autori rada su Tung-Hsiang C. i Jia-Lang S. , naslova „An intelligent multi-agent e-services method - An international telecommunication example“.

7.1 Primjer 1: Implementacija agentskog sustava za potrebe menadžmenta

Cilj je stvoriti dovoljno inteligentan sustav kojeg menadžment poduzeća mogu koristiti putem mobitela. Svoj višeagentski sustav nazivaju inteligentnim „MVAP-om“, odnosno Mobilna višeagentska paradigma (eng. Mobile Multi Agent Paradigm). Glavne funkcije istoga su sljedeće:

1. analiza postavljenog pitanja, sakupljanje informacija od odgovarajućeg izvora i formulacija informacija u odgovarajući odgovor;
2. izvršavanje instrukcija danih na temelju automatski sakupljenih informacija, utvrditi tko unutar poduzeća treba poduzeti akcije i distribuirati instrukcije s potrebnim informacijama.


Funkcije sustava se ostvaruju kroz šest glavnih komponenti:

1. **Modul za akviziciju podataka (MAP) – eng. DAM - „Data Acquisition Module“** – služi za „sirovo“ skupljanje podataka u stvarnom vremenu, rješavanje nedosljednosti u dobivenim podacima, filtriranje nevažnih i neželjenih podataka, komunikaciju s **MSP**-om kroz prezentaciju podataka u standardom formatu;
2. **Modul za sakupljanje podataka (MSP) – eng. DCA - „Data Collection Agent“** – komunicira s MAP-om, dobiva podatke od istoga, pohranjuje podatke u standardni format (u MPP, MES ili ERP), mapira baze podataka,

pretražuje relevantne informacije od **MPP-a**, komunicira s **AU-om** i daje semantičke analize te sakuplja informacije kao odgovor na upit;

3. **Modul za pohranu podataka MPP – eng. DSM – „Data Storage Module“** – ovaj modul je predana baza podataka koja pohranjuje podatke specificirane za poslovnu funkciju poput financija ili skladišta;
4. **Agent za upite (AU) – eng QA – „Query Agent“** – ova komponenta sustava analizira upite od korisnika, izvršava semantičku analizu, komunicira s **BKP-om**, formira i šalje upite zaduženom **MSP-u**, sakuplja i pohranjuje informacije kroz komunikaciju s **MPP-om**, formulira odgovor na upit korisnika;
5. **Administrativni agent (AA) – eng EA – „Enjoin Agent“** – analizira instrukcije ili naredbe od korisnika kroz semantičku analizu, izdaje upite potrebnim **MSP** –ima, sakuplja i pohranjuje informacije kroz komunikaciju s **MSP-om**, komunicira s **BKP-om** te šalje instrukcije zadanim osobama;
6. **Bežična komunikacijska platforma (BKP) – eng. WCP** – platforma je dizajnirana za sigurnu, brzu i „bezbolnu“ komunikaciju kroz sve elektronske terminale i vatrozide koji su u intranet aplikacijama na mobilnim uređajima.

Kako to izgleda s konceptualnog gledišta, prikazano je na slici 12.




Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, Expert Systems with Applications, 2011., br. 38 str. 738

Može se vidjeti kako je arhitektura sustava slojevita i jasno odijeljena. MAP moduli su jasno odijeljeni i pridruženi svojim MSP-ovima s pridruženim bazama podataka. Tu se vidi zašto postoje odijeljeni MAP-ovi i MSP-ovi. Dijele se na: prodaju (eng. sales), skladište (eng. warehouse) i financije (eng. financials). Nakon toga se podaci prosljeđuju kroz rad MSP-a na UA-e koji formiraju odgovore putem analiziranih informacija. Formirani odgovori se šalju putem BKP-a.

Kako je cilj ovoga diplomskog rada prikaz poslovnih agenata, prikazan je konceptualni rad svih poslovnih agenata, a prvi od njih je AU. Konceptualni model aplikacije se vidi na slici 13. Funkcije ovih agenata su:

1. komunikacija s BKP-om,
2. komunikacija s MSP-om,
3. analiza upita od korisnika i izdavanje zahtjeva za potrebnim informacija od strane MSP-a,
4. kolekcija svih pretraga od MSP-a i formiranje konačnog odgovora za korisnika,
5. prikazivanje rezultata upita, odnosno odgovora kroz BKP, korisniku.

Slika 13: Prikaz AU-a



Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, *Expert Systems with Applications*, 2011., br. 38 str. 739

Rad AU-u pokrenut je od strane korisnika i to putem upita. Funkcije tri i četiri mogu biti dalje podijeljene u tri modula. Prvi od navedenih je modul za analizu upita. Paradigma objekata koji su dostupne korisniku su: projekti, kvaliteta i kontrola proizvoda. Dostupni

podaci su: prodaja, skladište i financije. BKP preuzima enkriptiranu poruku od korisnika i kontaktira odgovajućeg AU-a. Nakon toga agent stvara upit koji se dekomponira u informacijske upite o prodaji, inventaru ili kontrole proizvoda. Funkcija AU je prvenstveno fokusirana na dobivanje optimalnih rješenja. Ova rješenja su bazirana na informacijama dobivenih od MSP-a.

Sljedeći modul je dekompozicijski modul. Nakon što se dobije upit od korisnika, agent mora identificirati vrstu potrebne informacije. Proces se ostvaruje kroz dekompoziciju koja upit pretvara u podatkovni oblik. On mora sadržavati listu podatkovnih upita koji su povezani s paradigmom objekata. Determinacija sadržaja u podatkovnom obliku je ostvarena kroz ekspertni sustav koji sadrži set pravila koja prolaze kroz proces zaključivanja. Nakon što se odredi koje pravilo je važeće, odnosno potreban podatkovni oblik, upit se može proslijediti odgovarajućem MSP-u.

Zadnja komponenta AU-a je modul za potporu odlukama. Nakon što prikupi potrebne podatke od prodajnog, inventarskog i financijskog MSP-a, agent pokušava naći optimalno rješenje na određeni upit. AU ovaj problem rješava tako da bira najbolji inferencijski model spremljen u ekspertnom sustavu kroz model koji koristi ograničenja upita. Nakon što je nađen primjereni matematički model, optimalno rješenje se izračunava na osnovu danih podataka. No inferencijski model ne može obrađivati upite, nego mora biti uparen s ekspertnim sustavom zato što mora biti osigurano adekvatno prikazivanje znanja ekspertnog sustava.

Sljedeći agent u sustavu je AA. Njegove funkcije su slične funkcijama AU-a. Razlike u njegovom radu su sljedeće :


1. naredbe su primaju od BKP-a, a ne do samoga upita,
2. neće raditi samo na traženim upitima, ujedno će skupiti kontaktne informacije poput broja mobitela, e-maila,
3. komunicirat će s BPK-om s potrebnim instrukcijama za pojedine korisnike, a ne za potrebe odgovora na upit korisnika.

Zadnji modul je MSP prikazan na slici 14. Sastoji se od četiri komponente:

1. **modul za sakupljanje podataka** – glavni zadatak modula je sakupljanje početnih podataka koje će ostali moduli obrađivati. Ovi podaci će biti spremljeni u bazu podataka. Podaci se uzimaju iz strojnog skeniranja pogona i inventara. Oni se šalju direktno u bazu podataka putem softvera za tu funkciju;
2. **rudar podataka modul** – ova komponenta radi glavni zadatak osiguravanja kvalitetnih podataka za analizu. Modul koristi razne metode klasteriranja podataka i određenu razinu optimizacije ovog procesa kroz fuzzy logiku. Ova komponenta

direktno komunicira s korisnikom putem generatora upita. Zahtjev prvo prolazi kroz njega;

3. **baza podataka** – ovaj modul se bavi čišćenjem podataka, njihove integracije, selekcije i transformacije. Informacije se koriste kroz OLAP kako bi se dobila suma svih važnih podataka. Ostali dijelovi su sučelja baze podataka i administratora;
4. **generator upita** – modul za stvaranje upita prema standardnom formatu. Zahtjev korisnika se prije slanja rudaru podataka standardizira i u izmijenjenom obliku šalje dalje.

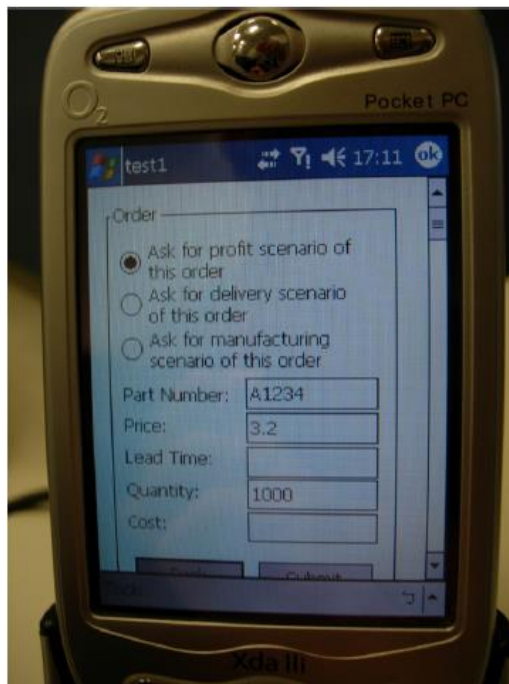


Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, *Expert Systems with Applications*, 2011., br. 38 str. 739

Na kraju ovoga primjera je prikazano kako sustav izgleda iz perspektive korisnika (slike 15, 16 i 17). Upit korisnika može se uputiti preko jednostavne mobilne aplikacije. Upit se stvara pomoću detaljnog opisa narudžbenice (slika 15). Korisnik upisuje potrebne podatke te ima mogućnost tri različita scenarija vezana uz proizvodnju, dostavu i profit. Prikazuje se prozor u kojem korisnik može postaviti parametre upita u tekstualnom obliku (slika 16).


Sustav obradi upit i šalje korisniku odgovor u obliku nekoliko mogućih scenarija. U odgovoru su sve važne kvantificirane informacije vezane za upit (slika 17).

Slika 15: Prikaz narudžbe



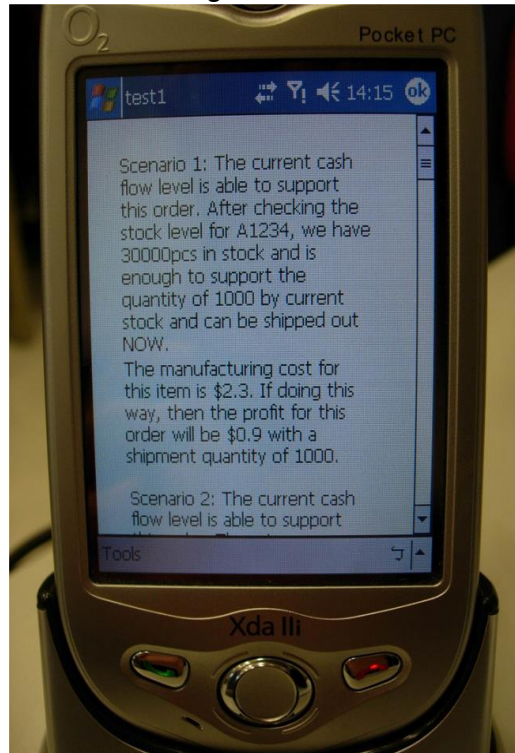
Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, *Expert Systems with Applications*, 2011., br. 38, str. 740

Slika 16: Upit korisnika



Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, *Expert Systems with Applications*, 2011., br. 38, str. 741

Slika 17: Odgovor sustava



Izvor: X.N. Jiang, K.L. Yung, A new intelligent system for senior executives to maintain remote control of their company, *Expert Systems with Applications*, 2011., br. 38, str. 741

7.2 Primjer 2: Implementacija agentskog rješenja u distribucijskom lancu maloprodaje

Sljedeći primjer prikazuje integraciju agentskog pristupa s RFID tehnologijom. RFID, odnosno Radio Frequency Identification je tehnologija koja koristi elektromagnetska polja radi automatske identifikacije i praćenja objekata. Pri primjeni se koriste dva elektronička uređaja, čitač koji je sposoban prepoznati i identificirati te čip koje ima svoj jedinstveni identifikacijski signal. RFID čipovi su okosnica ove tehnologije, odnosno tagovi (eng. tags). Tagovi mogu biti pasivni, pasivno-baterijski i aktivni. Pasivni tagovi nemaju ugrađeni energetska izvor, Zbog toga čitač mora biti uz čip i mora koristiti tri puta veću magnitudu signala nego što bi trebao kada bi tag imao svoj izvor energije. Pasivno-baterijski tag ima svoj izvor energije, odnosno bateriju koja se aktivira kada je čitač u blizini. Aktivni tag također ima bateriju, ali je ona za razliku od pasivno-baterijskog puno veća. Izvor energije je veći jer ovaj tag periodično šalje identifikacijski signal.

Može se primijetiti da RFID ima velike sličnosti s bar kod sistemom koji je prisutan u trgovinama. Obje tehnologije imaju čitač koji identificira i prepoznaje signale te tag ima jednaku svrhu kao magnetski bar kod, a to je sadržavanje potrebnih podataka o objektu na

kojem se nalazi. Ova tehnologija omogućava da tag bude samo za očitavanje te kao takav služi istoj svrsi kao i bar kod. Druga varijacija je tag koji može primati podatke koji su većinom vezani za objekt na kojem se nalaze. Između ove dvije vrste taga postoje inačice koje mogu programirati podatke samo jednom ili su samo za očitavanje, ali imaju više podataka namijenjenih za različite čitače. Čitač ne mora biti pokraj taga kako bi očitao podatke s njega. Udaljenost potrebna za komunikaciju ovisi o čitaču i vrsti taga te odgovarajućoj frekvenciji. Udaljenost može biti od dvadeset centimetara do dvjesto metara. Zbog velikog broja domena u kojima ova tehnologija može funkcionirati, mogućnosti pohranjivanja, ali i manipulacije podataka, RFID ima puno veću primjenu nego spomenuti bar kod.

Primjer predstavlja rješenje distribucijskog lanca. Kao takav uključuje u dizajn RFID tehnologiju i agentski sustav koji zajedno pokušavaju riješiti sljedeće probleme:


1. **neefikasno nadopunjavanje** (eng. inefficient replenishment) – inventura se radi ručno i periodično. Proizvodi se označavaju pripadajućim bar kodovima radi prepoznavanja njihove količine. Mana je što se proizvodi moraju pregledavati pojedinačno, preko sustava. Takav pristup nadopunjavanja zaliha poduzeća i trgovina propušta prilike koje se javljaju tijekom samoga procesa. Veća brzina bi omogućila poduzeću pravovremenu reakciju na promjene u količini potrebnih i željenih proizvoda;
2. **loša kontrola proizvoda na policama** (eng. poor control over the products hitting the shelves) – osobe zadužene za nabavu u trgovinama koriste osobno iskustvo pri određivanju količine željenih proizvoda kao i period njihove dostupnosti. Nestašica određenih proizvoda je česta pojava. To rezultira da kupci ne dobiju proizvod koji žele što se dugoročno odražava na prodaju tih proizvoda. Može doći do viška proizvoda za koje više ne postoji interes i takvi samo zauzimaju skladišni prostor;
3. **nedostatak trgovačkih usluga** (eng. lack of shopping services) – tijekom prodaje kupci žele obavljati kupnju u opuštenom okruženju. Nakon konzultiranja s prodavačima žele vidjeti i alternative za određeni proizvod. Isto tako imaju upite vezane uz raspoloživost robe ili slična pitanja. Prodavači dobivaju informacije vezane uz takva pitanja preko specifikacije proizvoda i stanja u skladištu. Stvaranje i implementacija interaktivnog servisa za obrađivanje ovakvih i sličnih upita daje priliku rasterećenja prodavača te omogućava kupcima dobivanje traženih informacija;

4. **neučinkovito korištenje informacija** (eng. inefficient utilization of information) – tradicionalno se svi proizvodi moraju registrirati kao uzeti pri prodaji. To vrijedi i za podatke koje služe kao baza za analizu prodaje i ponašanja kupaca. Aktivnosti poput micanja proizvoda s police, probavanja, usporedbe s drugim proizvodima se ne evidentiraju. Ako bi se preferencije kupaca mogle odmah spremirati u bazu podataka, onda bi se mogli brže dizajnirati proizvodi koji bi bili bliže željama kupaca.

Arhitektura aplikacije je podjeljena na dva glavna modula što je vidljivo iz slike 18. Prvi je modul za potporu kupcima, a drugi je modul za potporu menadžmentu. Modul za kupce predstavlja vanjski prikaz aplikacije. Modul za potporu menadžmentu je „back-end“ dio. Aplikacija radi svoje kompleksnosti ima tri sloja. Prikazani su od dolje prema gore:

1. fizički sloj – ovaj sloj sadrži i bavi se korištenjem RFID tehnologije. Poput senzornih uređaja i interaktivnih sustava koji služe kao infrastruktura aplikacijske platforme,
2. agentski sloj – čini ga veći broj agenata koji daju kupcima razne sugestije i odgovore na raspoloživost robe, isto daje menadžmentu preporuke vezane uz nadopunavanje i analizu polica,
3. aplikacijski sloj – predstavlja informacijski servis za kupce i menadžment kako bi cjelokupni sustav mogao biti realiziran.

Slika 18: Predložena sistemska arhitektura za prodavaonice



Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3061

Agentski sloj je međukomunikacijski sloj i komunicira s hardverdskim, fizičkim i aplikacijskim slojevima. Cilj je putem integracije agenata napraviti inteligentni način filtriranja i analize informacija koje se dobivaju od fizičkog i aplikacijskog sloja radi poboljšanja efikasnosti poslovanja poduzeća. Sustav je podijeljen na potporu kupcima i na potporu menadžmentu.

Na Slici 19 vidimo kako postoje četiri vrste agenata:

1. agent za ekstrakciju informacija,
2. agent za usluge prodaje,
3. agent za menadžment robe,
4. agent za integraciju informacija.


Agenti koji pripadaju modulu za potporu kupcima su agent za ekstrakciju informacija i agent za usluge prodaje. Oni imaju funkciju generiranja: personaliziranih preporuka, savjeta, online promocije i VIP³⁰ usluga. Rad tih agenata prikazan je na slici 22.

1. Agent za ekstrakciju informacija (eng. information extraction agent) – u trgovačkom slučaju očitava interakciju kupca i proizvoda već od početka

³⁰ Very Important Person

interakcije. Evidentira se svaka promjena na policama na kojima se nalazi proizvod neovisno o razlogu koji je naveo kupca da napravi interakciju s proizvodom. Možda je samo želio vidjeti detaljnije dizajn ili funkcionalnost proizvoda. Bilježi je li proizvod kupljen ili vraćen na policu. Takvi se podaci o ponašanju kupca bilježe i služe kao referenca trgovini pri procesu ponovne nabave. Sučelje nudi podatke vezane uz specifični proizvod, opis istoga i raspoloživi broj robe. Na slici 19 je vidljivo kako su podaci dostupni za sve proizvode unutar trgovine.


Slika 19: Agent za ekstrakciju informacija



Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, *Expert Systems with Applications*, 2011., br 38, str. 3065

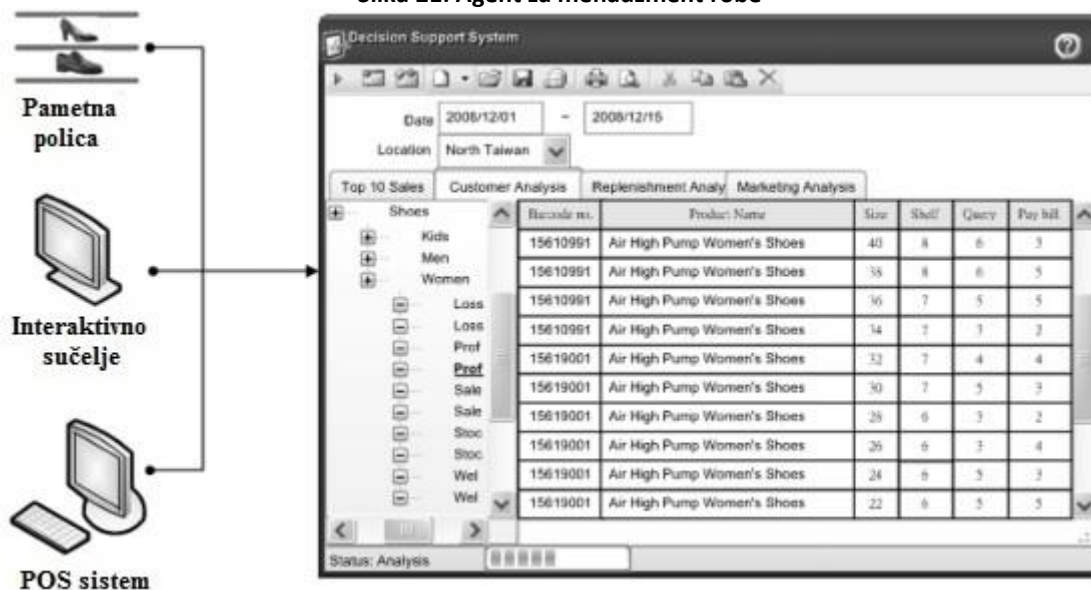
2. Agent za usluge prodaje (eng. sales service agent) – kada se kupac obrati agentu, agent filtrira informacije vezane uz specifikaciju upita i prezentira ih kupcu. Ujedno kupca informira o raznim promocijskim programima, preporukama za kupnju itd. Ispunjava funkciju prodavača pri interakciji s kupcem. Sučelje agenta je prikazano na slici 20.

Slika 20: Agent za usluge prodaje




Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3066

Slika 21: Agent za menadžment robe



Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3066

Slika 22: Rad modula za potporu kupaca




Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, *Expert Systems with Applications*, 2011., br 38, str. 3062

Agentima za potporu menadžmentu pripadaju agent za menadžment robe i agent za integraciju informacija. Agenti za potporu menadžmentu imaju funkciju efektivne analize informacija i usklađivanja informacija s agentom za usluge prodaje. Rade analizu tržišta, rasporeda na policama, ponašanja kupaca i daju preporuke vezane uz raspored polica. Rad agenata za potporu menadžmentu prikazan je na slici 23.

1. Agent za menadžment robe (eng. commodity management agent) – preuzima analizu prodaje od tradicionalnog POS (eng. point of sale) sustava radi kontrole zasebne prodaje u odnosu na cjelokupnu prodaju i informacija o proizvodima na policama. Kroz statistički proces analize ponašanja kupaca i prodaje generira preporuke za raspored proizvoda na policama i nabavu (slika 21).
2. Agent za integraciju informacija (eng. information integration agent) – stvoren je iz potrebe za prikupljanjem podataka i prikazivanjem relevantnih informacija višem menadžmentu poduzeća i koristi se pri formiranju rezultata prodaje, financijskog plana, logistike i transporta. Sakuplja sve podatke vezane uz proizvod i skupine proizvoda. Oni su uzeti iz oba modula radi kontrole i grupiranja. Ima funkciju dizanja efikasnosti robe u skladištima poduzeća, ali i pojedinačnim trgovinama.

Slika 23: Rad agenata za potporu menadžmentu




Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3062

Arhitektura cjelokupnog sustava je takva da su agenti povezani s inteligentnom servisno-integracijskom platformom (slika 24). Platforma implementira rješenja kako bi se otklonili prijašnji problemi u poslovanju. Funkcije su:

1. RFID tag generator (eng. RFID tag generator) – glavna mu je zadaća generiranje tagova na kojima su evidentirane osnovni podaci o proizvodu. RFID čitač je integrirani dio generatora i omogućava da RFID sistem i bar kod operacije budu sinkronizirani. Tagovi mogu držati podatke poput informacija o: proizvodnim linijama, povijesti proizvoda, pametnim policama, aplikaciji za interakciju s kupcima, ali i drugim agentima;
2. fiksna vrata (eng. fixed gate) – pomoću fiksnog RFID čitača na skladišnim vratima sustav može brzo brojati količinu robe koja dolazi ili odlazi. Sustav ima dva načina rada, ulazni i izlazni mod koji se koriste ovisno o tome zaprima li se ili raspisuje roba. Ako podaci koje fiksni čitač očita nisu kompletni, ne odgovaraju narudžbenici ili ih fiksni čitač ne može očitati, onda operator može ručnim čitačem očitati robu;
3. ručni RFID čitač – radnici koriste ovaj uređaj za zaprimanje robe i inventara. Rezultati se spremaju na platformu za poslovne operacije kroz agenta za integraciju informacija. Skladište je posebno kodirano kao i njegov interni raspored. Funkcija menadžmenta skladišta povezuje RFID tag s rasporedom unutar skladišta tako da zaposlenici mogu pratiti trenutačnu lokaciju robe putem RFID čitača;

4. pametna polica (eng. smart shelf) – kombinacija minijaturnog RFID taga, antene, korištenje distribuirane RFID komunikacije i kontrole čine pametnu policu. Putem poruka koje dopušta RFID sustav, antena koja je na proizvodu i antena na pojedinačnoj polici mogu komunicirati s agentom za ekstrakciju informacija radi prikazivanja traženih informacija kupcu;
5. platforma za interakciju s kupcima (eng. customer interaction application platform) – RFID čitač omogućava korisniku interaktivan kontakt s proizvodom. Povratne informacije koje kupac dobiva su: opis proizvoda, specifikacija i raspoloživi broj. Postoji i multimedijски dio ove platforme koji nudi savjete za kupovinu, slične promocije itd. Kada se platforma ne koristi, može prikazivati željene reklame ili promocije.



Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, *Expert Systems with Applications*, 2011., br 38, str. 3063

Na slici 24 prikazana je cjelokupna infrastruktura agentskoga rješenja. Tag koji služi kao okosnica sistema određuje se za određeni proizvod još u stadiju njegove proizvodnje. Proizvod ili skupina proizvoda se transportira u skladište distribucijskog centra. U ovom se procesu koriste fiksna vrata i ručni RFID čitači za brzu i preciznu obradu pristiglog inventara.

Dobiveni podaci se povezuju s modulom za potporu menadžmentu kroz funkciju agenta za integraciju informacija. Kada kupac uzme proizvod s pametne police pokrenut će rad agenta za ekstrakciju informacija koji služi kao podloga za ponovno nadopunjavanje proizvoda. RFID tag se također koristi za pokretanje modula za interakciju s kupcima i na kraju za pokretanje agenta za usluge prodaje. Nakon što kupac završi transakciju svi se podaci i informacije prosljeđuju agentu za upravljanje robe koji ih prikazuje menadžmentu poduzeća. Te su informacije ključne za planiranje budućeg poslovanja.

Specifikacije alata i opreme koji se koriste:

- antena koja se koristi za fiksna vrata je 4 TNC duplex antena port i ima komunikacijsko sučelje 10/100 Base-T Ethernet RJ45 konektor;
- antena na ručnim čitačima je „linearna s odličnom rasponom u polarizaciji“, komunikacijsko sučelje je Wi-Fi 802.11 b/g i fiksno/dinamička IP je podržana, operativni sistem je Microsoft Windows CE Professional 5.0;
- RFID sučelje na pametnoj polici je u skladu s EPC global C1 G2 standardom;
- aplikacija za interakciju s kupcima je Kiosk s 17-inčnim ekranom, matična ploča radi na frekvenciji od 4 GHz s 1 gigabajtom DDR2 radne memorije.

Ukupna integracija ovog sustava ima pet glavnih funkcija:

1. stvaranje identifikacije sadržaja za individualne proizvode (eng. creation of identification contents for individual product) – logistika same trgovine pokriva procese kao preuzimanje samih proizvoda, prodaje i itd. Kako bi se proizvod mogao efektivno pratiti on se identificira i evidentira kroz svaki dio procesa. To se obavlja pomoću RFID taga koji se programira i onda stavlja na proizvod ili kutiju. RFID tag i podaci u njemu se pišu u XML formatu te se kao takve lako očitavaju od strane aplikacije za prodaju.
2. ekstrakcija i upotreba informacija o proizvodima (eng. extraction and reuse of product information) – u trenutku kada roba namijenjena za prodaju dođe u prodavaonicu ona prolazi kroz RFID fiksna vrata. Pomoću RFID taga na proizvodu dobivaju se sve potrebni podaci. To uključuje odgovor na pitanje odgovara li proizvod traženoj količini i kvaliteti. Nakon što se proizvod ili skupina proizvoda primjereno uskladišti koristi se RFID ručni čitač za povremeno provjeravanje stanja proizvoda. Nakon toga agent za integraciju informacija ima ulogu predavanja dobivenih podataka iz ovoga procesa mobilnim uređajima kojima se služe zaposlenici zaduženi za inventar;

3. pristup analizi ponašanja potrošača u stvarnom vremenu (eng. real-time dynamic access to consumer behavior) – ostvaruje kontrolu ponašanja potrošača i stanja na policama u stvarnom vremenu. Ova studija ima više vrsta potrošnje proizvoda (osnovno, popularno, promocija, specijalna ponuda i ograničena količina) za planiranje rasporeda na policama. UHF RFID čitač se koristi kao medij, a police imaju više od jedne antene kako bi se omogućilo praćenje od strane agenta za ekstrakciju informacija. Dobivene informacije se koriste kao baza za analiziranje statusa bilo kojeg proizvoda u cilju efektivnije kontrole nad inventarom trgovine i budućim narudžbama koje ona izvršava;
4. pristup i povratne informacije od strane servisa za kupce (eng. access and feedback of the customer service information) – u trenutku kada kupac proizvod približi KIOSK-u za skeniranje, automatski se čitaju podaci iz taga i spremaju za analizu potrošača. U isto vrijeme agent za usluge prodaje procesira podatke poput statusa inventara za proizvod, preporuke za kupnju i prezentira ih na KIOSK-u;
5. potpora menadžmentu u funkciji prodaje (eng sales management decision support) – agent za menadžment robe počinje analizu u trenutku micanja proizvoda s police. On će pomoću antena i senzora percipirati je li proizvod u interaktivnom području ili se radi o stvarnoj kupnji kroz POS sustav. Ta informacija se kasnije može koristiti kao referenca za poslovne odluke i ponovne narudžbe robe, odnosno proizvoda.

Zaključak implementacije i analiza korisnosti

Analiza korisnosti sustava je prikazana kroz dva mehanizma usporedbe. Prvi je usporedba sadašnjeg stanja s prošlim. Drugi je direktna usporedba s drugim poduzećem koje koristi tradicionalne metode nabave, komunikacije s kupcima i prodaje. Grafikon prikazuje koje su razlike između prijašnje metode i sadašnje implementacije. Postoji veći broj pozitivnih promjena u ukupnom poslovanju. Oni su jasno vidljivi na slici 25 kao i u tablici 3.

Tablica 3: Promjena u poslovanju

Funkcije	Prijašnji sustav	Sadašnja platforma
Praćenje stanja na policama	nema	prisutan i baziran na RFID-u
Nestašića proizvoda	kontrola od strane zaposlenika (ljudsko iskustvo)	kontrola od strane sustava; jasno mjerljiva i prikaziva
Usluga kupcima	pasivna	samopomoć kroz KIOSK uređaj
Preporuke u kupovini	ostvaruju se od strane prodavača, koristi se njegovo iskustvo	preporuke se ostvaruju od strane umjetne inteligencije
Promocije proizvoda	ovisne o prognozama tržišta	osnovane na dana mining-u i dostupne u stvarnom vremenu
Preuzimanje robe	ljudski rad i bar kod sustav	koristi se RFID tehnologija
Kontrola inventara	ERP sustav	napredna analiza trendova od strane agenta
Ponovna nabava	alokaciju obavlja nadležni zaposlenih	alokaciju obavlja korisnik zajedno s automatskim elektorničkim sustavom


Nakon procesa implementacije vidljive su sljedeće prednosti:

1. **poboljšanje u poslovanju prodavaonica** – implementacijom sustava stvorena je infrastruktura koja omogućava rast u prodaji. Putem pametnih polica i RFID tehnologije koja s umjetnom inteligencijom, agentima, stvara veću razinu informiranosti kupca, ali i prodavaonice. Razne promocije i reklame mogu biti prikazani putem KIOSK-a. Reklame su ciljane, temeljene na ponašanju kupca i kupcu lako vidljive;
2. **poboljšanje u nabavi i veća efikasnost** – agent za ekstrakciju informacija i agent za upravljanje proizvodima koji su opisani u studiji mogu pratiti sve faze života proizvoda dajući potpunu kontrolu nad stanjem na policama i nad identifikacijom istog. Kroz agenta za integraciju informacija ostvarena je integracija s poslovnim

modulom sustava. To olakšava praćenje stanja na policama i u skladištu te proces nabave čini transparentnim. Time se smanjuju neprimjerene alokacije proizvoda u nabavi ili u slučaju krađe;

3. **redukcija u operacijskim troškovima skladišta** – bez instalacije RFID sustava u skladište, svaka roba i proizvod se mora pojedinačno skenirati pri ulasku i izlasku što predstavlja monotonu i vremenski zahtjevnu aktivnost. RFID sustav je omogućio čitanje velikog broja proizvoda u istom vremenu. To skraćuje vrijeme i smanjuje trošak radne snage koja kontrolira inventar u skladištu.

Slika 20: Grafikoni pozitivnih promjena



Izvor: Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3067

7.3 Primjer 3: Implementacija agentskog sustava u e-uslugama telekomunikacijskog poduzeća

Ovaj primjer se bavi integracijom cjelokupnog IS-a³¹ unutar telekomunikacijskog poduzeća. Autori smatraju da postoje dva važna faktora kada je u pitanju dizajn IS-a: bihevioralna znanost i znanost dizajniranja.³² Prvi određuje razvijanje i verifikaciju teorija koje objašnjavaju ljudsko i organizacijsko ponašanje. Drugi širi granice i mogućnosti organizacijskih i ljudskih sposobnosti. Uzimajući u obzir navedene faktore autori su došli na podjelu od šest prepreka koje predstavljaju okosnicu i razlog ove studije:

³¹ Infomacijski sustav

³² Eng. Design - science

1. **kaotično web-klijent okruženje (eng. chaotic web client environment)** – želja da se pruži funkcionalna internet usluga rezultirala je implementacijom raznolike i široke lepeze usluga koje prate želje klijenata. Nastaju poteškoće u upravljanju jer raznolika lepeza usluga predstavlja velike probleme u njihovoj integraciji;
2. **disruptivna internet usluga (eng. disruptive internet services)** – druge telekomunikacijske kuće imaju web-usluge, odnosno pozadinske zastarjele sisteme. Može se dogoditi da nisu potpuno kompatibilne, to jest da nisu jednako implementirane ili dizajnirane što predstavlja problem kada moraju zajednički raditi na više načina;
3. **neuskladive poslovne usluge/platforme (eng. incompatible business services)** – poduzeća često preuzimaju različite platforme i sisteme kroz poslovne akvizicije i spajanja. Naravno, sustavna integracija različitih platformi pomaže pri stvaranju određene razine integracije, ali ne može pružiti odmjerenu i homogenu uslugu koju B2B (eng. Business to business) klijenti traže. Upravljanje svim platformama i sustavima zahtijeva veći broj heterogenih adaptera koji se trebaju održavati i kontrolirati;
4. **neuredni poslovni procesi (eng. messy business processes)** – telekomunikacijska poduzeća nikada nisu u potpunosti riješili odnose između B2B zahtjeva i poslovnih procesa poduzeća. Programeri su, pokušavajući otkloniti taj problem, ispisali „traljave“ internet usluge koje se povezuju s poslovnim procesima;
5. **ad-hoc pristup eksternoj i internoj B2B integraciji (eng. handling of external and internal B2B integration)** – često kada telekomunikacijsko poduzeće ima želju komunicirati s partnerima, klijentima i dobavljačima, ono nema sistematski i metodološki način međuorganizacijske integracije procesa, njihove interoperabilnosti i menadžmenta. S rastućim B2B zahtjevima telekomunikacijske usluge pate od ad-hoc vremenskih i radno zahtjevnih manualnih promjena između unutarnjih i vanjskih poslovnih procesa;
6. **nedostatak telekomunikacijskih standarda za operacijske sisteme za potporu (eng. lack of telecommunication standards compliance for operation support systems)** – nedostatak standarda unutar industrije za upravljanje uslugama rezultira većim brojem suvišnih aplikacija koje dodatno kompliciraju pitanje heterogenosti.

Telekomunikacijski profil

Testna kompanija je jedna od najvećih na svijetu. Prema Forbesu, bila je jedna od top pedeset i top deset na azijskom kontinentu u 2008. Opseg usluga čine: lokalne usluge telefoniranja, izvandržavne telefonske usluge, internacionalni pozivi, mobilno komuniciranje, podatkovna komunikacija, internet usluge, broadband umrežavanje, satelitske komunikacije, inteligentno umrežavanje, multimedijalni broadband itd. Poduzeće se smatra jednim od iskusnijih i najvećih te ima preko dvadeset milijuna klijenata u pacifičkoj regiji.

Poduzeće posluje s većim brojem heterogenih i horizontalnih kompanija kao što su: Yahoo, APOL, PCCW, Sparq, Giga, Seednet itd. Većina njih ima globalnu prisutnost. Poduzeće je razvilo strategijsko partnerstvo s navedenim kompanijama. Kada navedena poslovanja pošalju svoj zahtjev, multiagentska metoda čini sljedeće akcije:


1. primanje zahtjeva klijenata neovisno o platformi koju koristi klijent,
2. spremanje klijentskih podataka u slučaju da legacy sistem ne radi,
3. primanje klijentskih podataka i ponovno slanje legacy sistema,
4. obavještanje klijenta o rezultatima.

Kao rješenje na navedenu problematiku kreirana je multiagentska metoda s inteligentnim sučeljem koji ima ulogu upravljanja, medijatora i transformacije podataka. Slika 26 prikazuje njenu arhitekturu i vezane sisteme. Vezani sistemi prikazani na slici djeluju na sljedeći način. Klijent šalje zahtjev putem **poslovnog portala e-usluge**. **Multiagentska okolina** predstavlja skupinu raznih agenata koji preuzimaju poslani zahtjev. On se obrađuje putem **EAI servisnog busa** i na kraju od strane **pozadinskog zastarjelog sustava**. U slučaju da ne može biti obrađen od strane navedenih, šalje se u **privremenu bazu podataka**. Agenti unutar okoline će iznova slati zahtjev iz baze podataka do trenutka kada može biti obrađen unutar **pozadinskog zastarjelog sustava**. Slika 26 prikazuje tri uloge agentskog rješenja. To su:

1. **upravljanje padacima (eng. data management)** – kada korisnik preda zahtjev unutar sustava, agent za menadžment podataka će napraviti transfer u specifični sloj u XML formatu. Svi agenti koordiniraju svoje ponašanje unutar ove specifikacije;
2. **mediator (eng. mediator)** – koordinira tijekom rada poslovnih procesa i započinje razmjenu podataka između agenata. Npr. agent determinira radno opterećenje back-end legacy sistema i odlučuje kada se zahtjev korisnika obrađuje. Ako legacy sistem radi, agent će poslati zahtjev korisnika i primiti vezane podatke, prepoznat će status sistema i prenijeti ga agentu u cilju potvrđivanja obavljene akcije. U protivnom će

zadržati zahtjev korisnika u privremenoj bazi podataka iz koje će kontinuirano slati zahtjev korisnika dok se ne zaprimi i izvrši.

3. **transformacija (eng. transformation)** – ova uloga vraća e-uslugu agentu koji je izdao izvorni zahtjev i determinira hoće li se vratiti u back-end legacy sistem ili u privremenu bazu podataka.




Izvor: Tung-Hsiang, C. Jia-Lang S., *An intelligent multi-agent e-services method—An international telecommunication example*, Information & Management, 2009., br. 46, str. 344

Agenti prisutni u sustavu prikazani su na Slici 27 skupa sa sustavima u kojima su u interakciji. Slika 27 predstavlja detaljni prikaz slike 26 jer prikazuje agente koji predstavljaju sustavno rješenje. Na slici je proces po kojem se zahtjev klijenta obrađuje s bojom odijeljenim ulogama rješenja koja su prije spomenuta. Prikazana je i podjela pozadinskog zastarjelog sistema. Njihov rad i međusobna interakcija je ilustrirana na slici 28. U nastavku teksta je objašnjenje rada agenata prikazanih na slikama 27 i 28 koji su objašnjeni kroz proces obrade zahtjeva unutar glavne podjele uloga rješenja:


1. **upravljanje podacima (eng. data management)** – uključuje web-agenta (WA) koji prikuplja sve korisničke podatke iz portala e-usluga i onda koristi agenta za transformaciju podataka (ATP) za enkodiranje u XML format;
2. **posrednik (eng. mediator)** – ima dva zadatka. Prvi je koordiniranje procesa agenata, a drugi uspostava usluga između agenata. Agent za koordiniranje odgovoran je i za superviziju ATP-a. Druga funkcija agenta za medijaciju (MA) je supervizija sistema kroz agenta za usluge koji prebacuje zahtjeve od agenta za tranziciju. Tako se zahtjevi

moгу mapirati u e-usluge. MA ima „plug in“ karakteristiku. On se priključuje agentu za pohranjivanje (AP) i agentu za aktivaciju (AA) pri provjeri dostupnosti. Kada sistem podbaci, agent za medijaciju primi poruku o statusu sistema od agenta za aktivaciju i aktivira agenta za pohranjivanje pa se zahtjev korisnika spremi u privremenu bazu podataka. Kada back-end sistem bude sposoban za primanje zahtjeva, MA će reći agentu za aktivaciju da nađe spremljeni korisnički zahtjev i rezultat će se poslati korisniku;

- transformacija (eng. transformation)** - premješta zahtjev korisnika u e-usluge. Prepoznavajući važnost informacija vezanih za zahtjev korisnika, dodana su dva agenta. Agent za distribuciju (AD) i agent za tranziciju (AT). AD prima zahtjev korisnika od ATP-a u XML obliku i mapira e- usluge na TSA.




Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, Information & Management, 2009., br. 46, str. 345



Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, Information & Management, 2009., br. 46, str. 345

Poslovni procesi koji se obrađuju su od multiagentskog mehanizma prikazani su na slici 29. Procesu određuju koji agenti će biti korišteni prema podjeli agenata kao i koja je njihova uloga. Slika prikazuje četiri poslovna procesa s vezanim agentima. Objašnjenje i podjela:

- ✓ online poslovni procesi menadžmenta koji izvršavaju normalne procese dok svaki resurs radi unutar normalnog statusa i operativnog rada,
- ✓ offline serija poslovnih procesa menadžmenta izvrši neuobičajen legacy sistem i pošalje informacije o korisniku,
- ✓ semi-offline serija poslovnih procesa menadžmenta je slična kao druga, ali ako agent za procese vrati neuobičajenu sistemsku poruku TSA-a, poslat će zahtjev korisnika za navedeni proces,
- ✓ online serija poslovnih procesa menadžmenta je još jedan normalan proces. On će ponovno poslati zahtjev korisnika uzet iz offline serije i semi-offline poslovnog procesa agentu za uspostavu usluge.



Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, *Information & Management*, 2009., br. 46, str. 345

Implementacija prototipnog rješenja


Prototipno rješenje je implementirano u Visual Studio. NET 2005. i SQL 2005. EAI/ESB implementiran je u NET Framework i Tibco. Windows Sever 2003. koristi IIS i NET. Framework SDK služi kao aplikacijski server za razvijanje web-servisa i generalnih e-usluga gateway-a. Inteligentne multiagentske e-usluge imaju sljedeće značajke:

1. validacija i konektiranje podataka za korisnike,
2. verifikacija i transformacija korisničkih informacija,
3. integracija internet usluga unutar tvrtke,
4. upravljanje portalom radi stvaranja raznolikih usluga.
- 5 .uspostavljanje poslovnih usluga,
6. streamlining heterogenih sučelja za usluge,
7. akceleracija razvoja, održavanja i ponovnog korištenja web-aplikacija.

Implementacijska struktura je web bazirana i ima pet okruženja e-poslovanja. To su: klijenti, certifikati (autorizacija police), web-serveri, aplikacijski serveri i back-end legacy sistem. Na slici 30 je prikazana infrastruktura web-stranice i kroz pet koraka su okarakterizirani procesi web-stranice:

1. **klijenti** su aktori u modelu e-poslovanje. Svaki korisnik može pregledati web-stranicu poduzeća s bilo kojeg uređaja koji ima pristup internetu. Tu kupci šalju svoje zahtjeve i upite;
2. **certifikati** – autorizacijski standardi su tu da preventiraju internetski kriminal. E-usluge otkrivaju osjetljive informacije izvan samoga poduzeća. Zato se standardi za autorizaciju moraju inkorporirati kako bi zaštitili podaci od neželjenog pristupa;
3. **web serveri** su, naravno, u prvom planu operacija e-poslovanja. Oni daju usluge web-stranice i zaprimaju zahtjeve klijenata. Web serveri su locirani iza vanjskih vatrozida. Nakon što klijent prođe certifikat (autorizacijski standard) može koristiti preglednik za navigaciju kroz usluge poduzeća;
4. **aplikacijski serveri** kontroliraju sve telekomunikacijske elektronske usluge. Oni uključuju poslovnu logiku samog poduzeća. Njihove operacije primaju zahtjeve klijenata i šalju instrukcije back-eng legacy sistemu. Operacije uključuju upite za status i instalaciju opreme, pregledavanje opreme, preuzimanje svih žalbi ili zahtjeva. Generiraju izvještaj za klijenata i izvršavaju zahtjeve klijenata;
5. **zastarjeli pozadinski sistem** predstavlja temelj operacija u telekomunikacijskom poslovanju. Oni su odgovorni za upravljanje klijentovim zahtjevima.

Slika 21: Ilustracija infrastrukture web-stranice

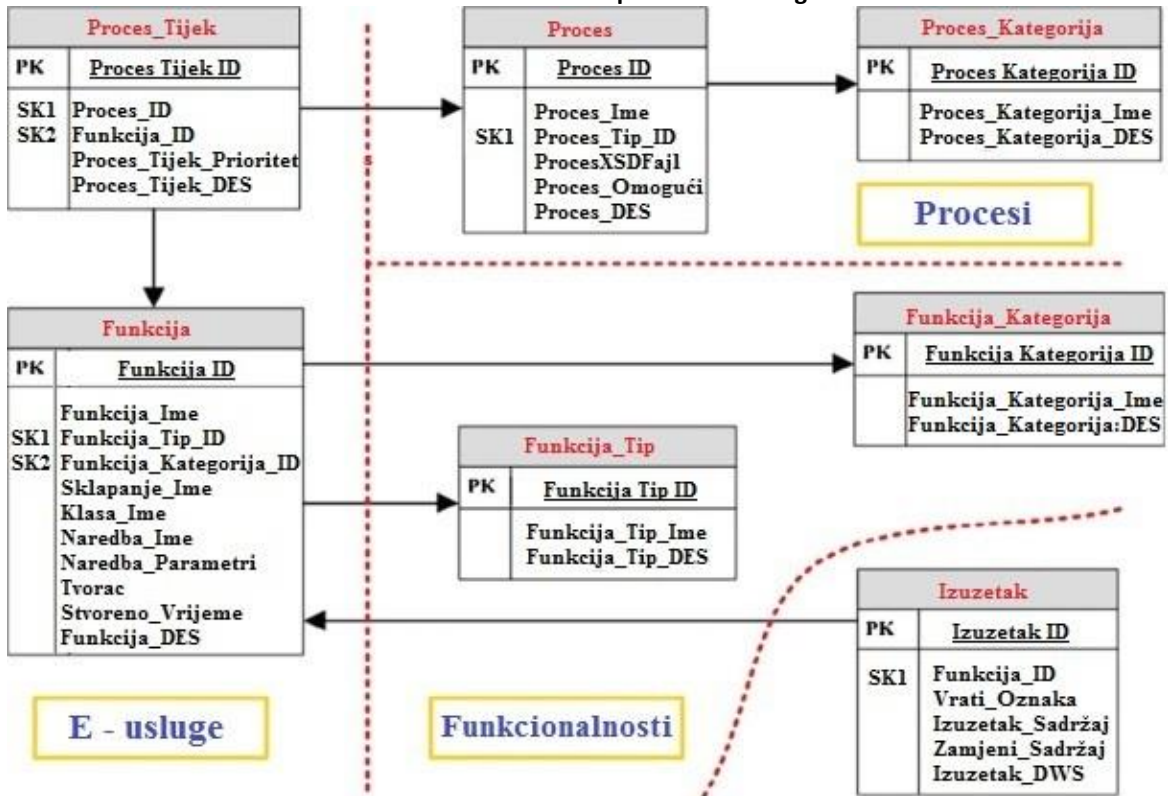


Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, *Information & Management*, 2009., br. 46, str. 346

Modeli podataka, odnosno meta-podatka koji se koriste unutar e-usluga su promijenjeni radi olakšavanja rada. Model se sastoji od šest tablica podijeljenih u tri skupine podataka: **funkcionalnost**, **proces** i **e-usluge**. Podjela je prikazana na slici 31 (isprekidanim crvenim linijama) i ima sljedeće karakteristike:


1. **funkcionalnost** – Funkcionalnost_Tip i Funkcionalnost_Kategorija (eng. Functionality of Function_Type and Function_Category) – opisuje sve usluge u telekomunikacijskom poslovanju. Većina njih dobivena je od zahtjeva kupaca. Funkcija_Kategorija opisuje svaku funkciju, a Funkcija_tip zapisuje generalnu vrstu telekomunikacijske usluge;
2. **proces** – Proces_Logika i Proces_Kategorija (eng. Processes of Process_Logic and Process_Category) – definira poslovnu logiku telekomunikacijskog poslovanja i preuzima bazu podataka kako bi pružila telekomunikacijske usluge. Procesi validiraju input informacije (zahtjev klijenta) i opisuju aktivni status procesa; Proces_Kategorija klasificira telekomunikacijske procese.
3. **e-usluge** – Proces_Tijek i Funkcija (eng. e-Services of Process_Flow and Function) – opisuje vanjske telekomunikacijske servise i unutarnje poslovne procese. Funkcija zapisuje vanjske operacije i informacije o njegovom kreatoru. Proces_tijek zapisuje sekvencu poslovnog procesa i vezuje ga uz tablicu Funkcionalnost.

Slika 31: UML baze podataka e-usluga



Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, Information & Management, 2009., br. 46, str. 347

Slika 222: UML dijagram sekvenci agentskog rješenja



Izvor: Tung-Hsiang, C. Jia-Lang S., An intelligent multi-agent e-services method—An international telecommunication example, Information & Management, 2009., br. 46, str. 348

Studija učinka

Radi sumiranja svih funkcionalnosti agentskog rješenja na slici 32 se nalazi UML dijagram sekvenci. Slika objašnjava rad agentskog rješenja sa svim povezanim sistemima. Slikom je lakše vizualno predstaviti rad i interakciju s drugim sistemima, poput pozadinskog zastarjelog sustava, i sumirati rješenje unutar studije učinka. Tijekom procesa implementacije putem analize učinka evidentirane su sljedeće prednosti:

1. redukcija žalbi klijenata na same e-usluge – ponekad se web-stranica prikazivala kao nedostupna klijentima jer bi pogrešne operacije unutar legacy sistema dovele do sistemskih greški. Nedostupnost bi stvarala probleme klijentima, uzrokovala zbunjenost klijenata i takva situacija bi rezultirala većim brojem pritužbi i žalbi. Nakon implementacije multi-agentskog sistema u 2004. poduzeće je smanjilo broj pritužbi i veći broj klijentskih zahtjeva obrađuju se uspješno i automatski. Povećan je kapacitet jednako kao i kvaliteta u prodaji i naplati usluga;
2. donošenje tacidnog znanja u smislu poboljšavanja menadžmenta – uspostavom multiagentske platforme efektivno su riješeni problemi menadžmenta i sukobi između različitih zahtjeva klijenata i zastarjelog sistema;
3. poboljšavanje menadžmenta pozadinskog zastarjelog sistema – uzeti su brojevi uspješnih i neuspješnih obrađenih zahtjeva kao mjerilo performansi.

Zaključak primjera

Ova metoda pri obradi zahtjeva korisnika predstavlja sistematski i metodološki pristup za menadžment B2B lanca. Preventira se kaotična konekcija od točke do točke i rješenje se predstavlja B2B lancu s fleksibilnošću i jednostavnošću. Glavne karakterisike nove metode su:

1. sve usluge imaju jasno određene granice koje identificiraju svrhu i portal za svaku,
2. usluge ne ovise o vanjskom sustavu,
3. XML baziran sustav meta podataka e –usluge koristi ustaljene podatkovne sheme i validaciju podataka radi razmjene informacija,
4. e-usluge mogu koristiti poslovno znanje za opis konekcije: port, podatke, funkciju i sigurnosna pravila;
5. interoperabilnost omogućava poslovnim partnerima da dobiju pristup podacima i poslovnim funkcijama putem e-usluga.

8. Zaključak

Agent može korisniku omogućiti lakše snalaženje kroz svakodnevne obaveze. On preuzima dobar dio opterećenja koje stvara preopterećenje informacijama. Dobra analogija je da u moru informacija postoji čamac koji može dovesti na mjesta gdje korisnik želi biti. Više ne pliva sam u „moru podataka“, oslobođen je kako bi pažnju obratio na smjer kojim ide. Agenti rade upravo to, oslobađaju korisnika u svakodnevnim zadaćama. Prema svojoj definiciji, program koji samostalno obavlja akcije u ime korisnika je agent. No gdje se takav softver može primijeniti? Moguća primjena agenata ovisi o dvije stvari. Prva je infrastruktura – računalna oprema, senzori, odnosno sve hardverske komponente. Dakle, sva fizička oprema potrebna da agent može obavljati svoju funkciju. Druga je sam agent kojeg čini kvalitetan kod koji je samostalan i dovoljno inteligentan za obavljanje zadane funkcije. Kod predstavlja softversku komponentu. Istinski, implementacija agenta ovisi o puno više faktora nego što su ova dva. Navedena dva dijela su najvažnija jer bez njih agent ne može postojati. U prijašnjim poglavljima oni su nazvani *arhitektura* i *program*. Implementacija određenog poslovnog inteligentnog agenta ovisi i o drugim faktorima kao što su: novac, vrijeme, isplativost, educirani kadrovi koji su sposobni implementirati rješenje itd. U konačnici, ti faktori odlučuju gdje i kako će se u poslovanju implementirati agentska rješenja poslovnih problema.

Odgovor na pitanje implementacije agenata leži u kreativnosti implementacije koja može ograničavati njegovu primjenu. Ovo je čisto teoretski odgovor koji nema svoju vrijednost u poslovnoj okolini. Zato mora biti proširen i dalje definiran. Za tu svrhu će biti iskorišteni sami primjeri unutar rada. Iz njih se mogu prikazati generalizirani zaključci. Prvi od njih je taj da kada se govori o stvarnom implementiranom agentskom rješenju, misli se na agente, a ne agenta. Ovo je istinito kroz sve primjere. Agent nikada nije implementiran u svoje poslovno okruženje sam, uvijek je implementirana skupina agenata. Razlog je što su poslovni zahtjevi poduzeća kompleksni. Što je kompleksniji zahtjev, agent mora biti složeniji. No stvoriti tako velikog i kompleksnog agenta je vremenski i resursno zahtjevan posao koji nema zajamčen uspjeh, kao i stvaranje grupe agenata. Ali stvaranje više malih agenata u odnosu na jednog velikog ima jednu prednost, pogotovo u poslovanju, smanjenje rizika neuspjeha. U programiranju velika razina kompleksnosti programa jamči veću razinu programskih grešaka, odnosno bugova. To u poslu može rezultirati gubitkom novca, zbog

dugog vremena koje mora biti utrošeno na eliminaciju bugova. Lakše je stvoriti i pratiti desetak malih agenata, nego jednog iste veličine (pri tome se misli na veličinu programskog koda) i kompleksnosti. Agenti zajedno tvore agentski sustav koji nudi istu funkcionalnost kao jedan agent. Također, programiranje više malih agenta je više u duhu objektivnog programiranja jer daje veću razinu decentraliziranosti rješenja i omogućava lakše unaprjeđenje ili zamjenu neke funkcije. Takav „zahvat“ se može napraviti bez utjecaja na cijelo agentsko rješenje.

Agentska rješenja su optimalna samo kada poduzeće procesuiru i analizira velike količine podataka, iz njih vuče svoje akcije i korisne informacije. Agenti mogu biti implementirani bilo gdje unutar poduzeća, ali su najučinkovitiji kada se koriste u području u kojem je uočen problem radi kojeg su stvoreni, pritom se misli na preopterećenost informacijama. Poslovna funkcija koja je najviše pogođena tim problemom je menadžment. U sva tri primjera poslovnih agenata koji su prikazani u radu evidentirana je povezanost agenata s uspješnim menadžmentom. Učinkovitija prodaja i nabava su u većini slučajeva povezani s agentskim poslovnim rješenjem.

Inteligentni poslovni agenti su zasada povlastica velikih poduzeća i korporacija. Razlog što ovakva vrsta programa još nije doživjela svoju široku komercijalizaciju i primjenu je što ne postoji poduzeće koje nudi gotova agentska rješenja namijenjena poslovnim subjektima. Rješenje se uvijek stvara, a taj proces zahtijeva veliku količinu stručnih kadrova i novca, a to imaju samo veća poduzeća.

Konačno, postavlja se pitanje koliko će pojedino poduzeće beneficirati od inteligentnih poslovnih agenata i jesu li te beneficije lako i jasno mjerljive. U nastavku dajem odgovor na postavljenu hipotezu na početku rada. Drugi primjer poslovnog agenta koji je u radu analiziran daje jasan i mjerljiv odgovor. Misli se na rad akademika Kun-Chieh Y., Ruery-Shun C. i Chia-Chen, C. : „Intelligent service-integrated platform based on the RFID technology and software agent system“. Točnije, slika 25 „Grafikoni pozitivnih promjena“. Prvo promjena je drastično smanjenje stope nestašica robe na policama za devedeset posto, odnosno pad s trideset i četiri posto na tri cijela četiri. Smanjenje vremena inventure za osamdeset posto, odnosno pad s jedan cijela dvadeset i pet sati na dan na nula cijela dvadeset i pet. Pad troškova skladišta za šezdeset i osam posto, odnosno pad s dva cijela pet neto milijuna dolara na mjesec na nula cijela osam. Dakle, implementacija agenata može imati prednosti smanjenja troškova i vremena potrebnog za obavljanje određenih poslovnih radnji. Značajna je i razina zadovoljstva kupaca koja je povećana za dvadeset i dva indeksa. Promjena u prodaji, odnosno povećanje prodaje za četrnaest posto nije zanemariv postotak,

odnosno povećanje s devetnaest cijela šest na dvadeset i dva cijela tri neto milijunima dolara na mjesec. Mjesečna promjena od dva cijela sedam neto milijuna dolara jasno prikazuje beneficiani učinak agenta u poslovanju. Razdoblje ove promjene ipak je period od mjesec dana. Što u poslovnom svijetu je maleni vremenski interval za značajne promjene koje mogu rezultirati prikazanom porastu profita. Navedeni podaci prikazuju da odgovor na postavljenu hipotezu je pozitivne naravi. Moguće je primjenom agenata unaprijediti postojeće poslovne funkcije poduzeća.

Implementacija inteligentnih poslovnih agenata donosi smanjenje vremena i troška pri obavljanju određenih poslovnih funkcija te rasterećuje nositelje tih funkcija, ali donosi i povećanje mogućnosti poduzeća da reagira na potrebe svojih kupaca i analizira ih na način koji prije agenata nije bio moguć. To je posljedica agentove mogućnosti analize i reakcije na informacije koje prima iz svoje okoline. Dokaz ovoj tvrdnji je dvoznamenkasti porast prodaje (profita) u primjeru dva što je glavni cilj većine poslovnih subjekata.

9. Literatura

Knjige:

- Efraim, T. Ramesh E, S. Dursun, D. , Business Intelligence and Analytics: Systems for Decision Support - 10th edition, Prentice Hall, New Jersey, 2010.
- Jeffrey M. B. ,Software Agents, MIT Press, Cambridge, 1997.
- Stuart, R. Peter, N. ,Artificial intelligence-a modern approach, Pearson Education Inc. , New Jersey, 2003.

Časopisi:

- I. S. Rudowsky, Intelligent Agents, Communications of the Association for Information Systems, London, 2004., Volume 14, str. 275. - 290. ,
- Kun-Chieh, Y. Ruery-Shun, C. Chia-Chen, C., Intelligent service-integrated platform based on the RFID technology and software agent system, Expert Systems with Applications, 2011., br 38, str. 3058. – 3068.
- Samir Chopra., Rights for Autonomous Artificial Agents, Communications of the ACM, 2010., vol. 53. Br. 8, Str 38 - 40
- Tung-Hsiang, C. Jia-Lang S. ,An intelligent multi-agent e-services method—An international telecommunication example, Information & Management, 2009. br. 46, str. 342. – 350.,
- X.N. Jiang, K.L. Yung , A new intelligent system for senior executives to maintain remote control of their company, Expert Systems with Applications, 2009., br. 38 str. 736. – 742,

Internet izvori :

- <http://www.theguardian.com/business/2009/may/18/digital-content-expansion>, uzeto 20.7.2014
- World Wide Web Consortium, uzeto 30.8.2014.

Popis slika i tablica

- Slika 1: Stablo UI-a, str. 9
- Slika 2: Odnos agenta i okoline, str. 12
- Slika 3: Dimenzije i vrste agenta, str. 18
- Slika 4: Učinci inteligentnih agenata unutar organizacijskih, socialnih i tehnoloških okvira, str. 23
- Slika 5: WEB 3.0 slojevi, str. 26
- Slika 6: Model refleksnog agenta, str. 31
- Slika 7: Funkcija refleksnog agenta, str. 31
- Slika 8: Model reflexsnog modeliranog agenta, str. 33
- Slika 9: Funkcija reflexsnog modeliranog agenta, str. 34
- Slika 10: Model ciljno baziranog agenta, str. 35
- Slika 11: Korisno bazirani agent, str. 36
- Slika 12: Objektni prikaz MVAP-a, str. 40
- Slika 13: Prikaz AU-a, str. 41
- Slika 14: Arhitektura agenta, str. 43
- Slika 15: Prikaz narudžbe, str. 44
- Slika 16: Upit korisnika, str. 44
- Slika 17: Odgovor sistema, str. 45
- Slika 18: Predložena systemska arhitektura za prodavaonice, str. 48
- Slika 19: Agent za ekstrakciju infomacija, str. 49
- Slika 20: Agent za prodaju robe, str. 50
- Slika 21: Agent za menadžment robe, str. 50
- Slika 22: Rad modula za potporu kupaca, str. 51
- Slika 23: Rad agenta za potpora menadžmentu, str. 52
- Slika 24: Arhitektura integrirane inteligentne uslužne platforme, str. 53
- Slika 25: Grafikoni pozitivnih promjena, str. 57
- Slika 26: Arhitektura inteligentne multiagentske metode e-usluga, str. 60
- Slika 27: Komponente inteligentne multiagentske metode e-usluga, str. 61
- Slika 28: Interakcija i menadžment metode, str. 61
- Slika 29: Četiri kategorije menadžmenta poslovnih procesa e-usluga, str. 62
- Slika 30: Ilustracija infrastrukture web-stranice, str. 64
- Slika 31: UML baze podataka e-usluga, str. 65
- Slika 32: UML dijagram sekvenci metode, str. 65
- Tablica 1: Primjeri dostupnih agenata, str. 17
- Tablica 2: Usporedba ostalih softvera i agenta, str. 19
- Tablica 3: Promjena u poslovanju, str. 56