Inteligentni agenti u elektroničkom poslovanju

Cvek, Loris

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:636473

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-24**

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

Sveučilište Jurja Dobrile u Puli

Fakultet ekonomije i turizma

„Dr. Mijo Mirković“

Loris Cvek

Inteligentni agenti u elektroničkom poslovanju

Završni rad

Pula, 2020.

Sveučilište Jurja Dobrile u Puli

Fakultet ekonomije i turizma

„Dr. Mijo Mirković“

Loris Cvek

Inteligentni agenti u elektroničkom poslovanju

Završni rad

Loris Cvek

JMBAG: 0303065595, redovan student

Studijski smjer: Informatički menadžment

Kolegij: Elektroničko poslovanje

Mentor: prof. dr. sc. Vanja Bevanda

Pula, kolovoz 2020.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani _____, kandidat za prvostupnika ekonomije/poslovne ekonomije, smjera _____ ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

_____

U Puli, _____, _____ godine

IZJAVA

o korištenju autorskog djela

Ja, _____ dajem odobrenje Sveučilištu Jurja Dobrile

u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom

_____

_____

_____ koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, _____ (datum)

Potpis

_____

SADRŽAJ

1. Uvod 1

2. Uvod u elektroničko poslovanje 2

2.1 Definicija elektroničkog poslovanje i elektroničke trgovine 2

2.2 Različite vrste i modeli elektroničkog poslovanja 4

2.3 Prednosti i nedostaci elektroničkog poslovanja 5

2.3.1 Prednosti elektroničkog poslovanja 5

2.3.2 Nedostaci elektroničkog poslovanja 6

3. Implementacija elektroničkog poslovanja i upravljanje poslovanjem malih i srednjih poduzetnika 7

3.1 Sustav za upravljanje dokumentacijom 8

3.2 Planiranje resursa poduzeća (eng. Enterprise Resource Planning – ERP) 9

4. Umjetna inteligencija 11

4.1 Što je umjetna inteligencija? 11

4.2 Klasične metode u umjetnoj inteligenciji 11

4.3 Moderne metode u umjetnoj inteligenciji 12

5. Inteligentni agenti 13

5.1 Što su inteligentni agenti? 13

5.2 Struktura inteligentnih agenata 13

5.3 Vrste inteligentnih agenata 14

6. Primjena inteligentnih agenata 20

6.1 Primjena inteligentnih agenata u elektroničkom poslovanju 20

6.1.1 Inteligentno pretraživanje i filtriranje, te rješevanje problema preopterećenosti informacijama 22

6.2 Inteligentni agenti za razgovor tijekom online prodaje 22

6.2.1 Struktura inteligentnih agenata za razgovor 23
6.3 Ciljano oglašavanje korištenjem inteligentnih agenata 25
6.3.1 Čimbenici ciljanog oglašavanja i postupak istraživanja tržišta 25
6.3.2 Model inteligentnog agenta za ciljano oglašavanje 26
6.3.3 Skupljanje informacija i algoritam ciljanja 27
6.4 B2C elektronička trgovina bazirana na inteligentnim agentima 28
6.4.1 B2C elektronička trgovina i inteligentni agenti 28
6.4.2 Podsustavi inteligentnih agenata u B2C trgovini 30
6.5 Inteligentni agenti u zdravstvu tijekom aktualne pandemije koronavirusa COVID-19 31
7. Zaključak 33
POPIS LITERATURE 34
POPIS SLIKA 36
SAŽETAK 37
SUMMARY 38

1. Uvod

Elektroničko poslovanje i umjetna inteligencija učinili su život čovječanstva lakšim i fleksibilnijim nego što je on to bio prije. Najviše se to odnosi na sustav trgovine u cijelome svijetu, jer je danas puno lakše obaviti kupovinu nego što je to bilo prije. Prije se moralo otići u dućan, pogledati razne proizvode i onda tek kupiti proizvod ili ako nismo bili zadovoljni izborom otišli bi u druge dućane. Najveći problem u svemu tome je bilo da bi čovjek izgubio dosta vremena. Danas zahvaljujući elektroničkom poslovanju i još više umjetnoj inteligenciji, kupac ode na internet trgovinu, razgleda proizvode te ako mu se ne sviđa ode na stranicu druge trgovine te tamo obavi kupnju, i to sve iz svog doma. U dućanu ako trebate pomoć uvijek su na raspolaganju djelatnici, a na internetu su to inteligentni agenti koji su danas toliko razvijeni da prate korisnika od početka do kraja kupovine. Ovaj rad se sastoji od pet cjelina, u prvoj cjelini objašnjeno je što je elektroničko poslovanje, kako ono funkcionira te koje su prednosti i nedostaci elektroničkog poslovanja. U drugoj cjelini govori se implementaciji elektroničkog poslovanja u poslovanju malih i srednjih poduzetnika, zašto je implementacija elektroničkog poslovanja učinkovita te na koji način olakšava rad zaposlenicima u poduzeću. Treća cjelina govori o umjetnoj inteligenciji, kako umjetna inteligencija funkcionira i koje su metode umjetne inteligencije. U petoj cjelini se počinje govoriti o inteligentnim agentima što je uvod u šestu cjelinu koja govori o primjeni agenata u elektroničkom poslovanju.

2. Uvod u elektroničko poslovanje

2.1 Definicija elektroničkog poslovanje i elektroničke trgovine

Elektroničko poslovanje je primjena informacijskih i komunikacijskih tehnologija (ICT) kao podrška svim poslovnim aktivnostima.[1] Govoreći o elektroničkom poslovanju, ono olakšava poslovanje svim poduzećima jer na taj način poduzeća štede novac i vrijeme. Pomoću elektroničkog poslovanja, poduzeća povećavaju svoju konkurentnost na tržištu i nastoje privući još više klijenata na svoje tržište. To je kombinacija tehnologije, organiziranja, procesa i različitih razmišljanja. Tehnologija se u današnje vrijeme koristi kako bi se razvili novi proizvodi ili radi proizvodnje u globalu, te radi poboljšanja marketinga i prodaje, odnosno oglašavanja. Elektroničko poslovanje pomaže malim i srednjim poduzetnicima da poboljšaju svoje usluge i dobiju pristup kupcima izvan lokalnog tržišta, povećaju vidljivost za kupce i partnere, smanje troškove marketinga, uspoređuju proizvode i cijene, smanje troškove povezane s poslovnim transakcijama te komuniciraju ili posluju, a da se ne nalaze na istoj lokaciji.[2] Poduzeća koja koriste elektroničko poslovanje moraju stalno pratiti tehnološke promjene i trendove jer ako poduzeće tehnološki zaostaje konkurencija bi ga vrlo brzo i lako mogla eliminirati s tržišta. Primjer tomu može biti razvoj aplikacije tako da stalno bude modernizirana s današnjim standardima i da bude dostupna svim korisnicima, pratiti na kojim se društvenim mrežama kreće velik broj korisnika i tamo se više oglašavati.

Elektronička trgovina dio je elektroničkog poslovanja koji služi za prodaju različitih proizvoda, usluga pa čak i informacija putem interneta. Kod elektroničke trgovine, kao i kod svih ostalih oblika prodaje na daljinu, sklapanje ugovora o kupoprodaji između trgovaca i potrošača odvija se bez fizičkog kontakta, korištenjem jednog ili više sredstava daljinske komunikacije npr. putem interneta.[3] Postoje više vrsta elektroničkih trgovina koji se razlikuju po sudionicima u transakcijama o kojima ćemo više pričati kasnije.

[1] BEGOVIĆ, S. i PENIĆ, S. (2014.) *Poslovanje.* Zagreb. Ministarstvo poduzetništva i obrta. Str. 13.
[2] Ibid.
[3] https://www.mingo.hr/page/kategorija/e-trgovina 26.07.2020

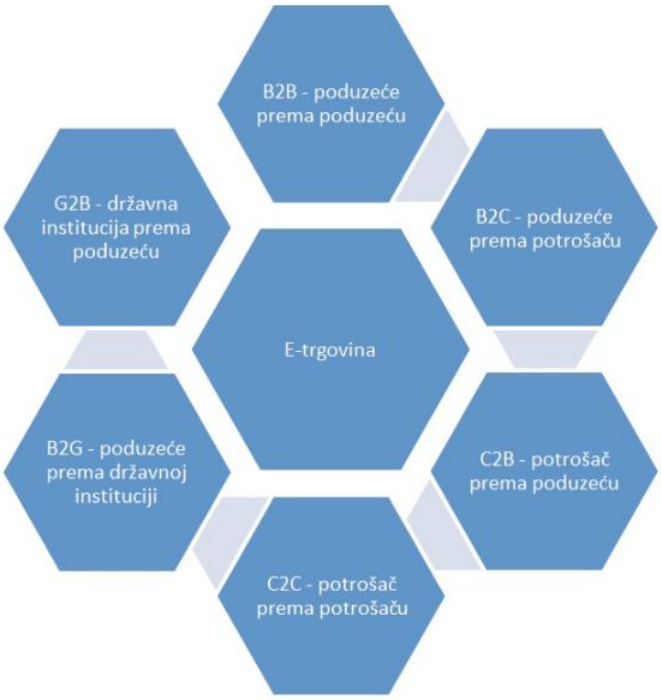

Slika 1. Vrste elektroničkih trgovina po sudionicima u transakcijama

Izvor: https://www.mingo.hr/page/kategorija/e-trgovina - 26.07.2020

U svijetu najpoznatije elektroničke trgovine su eBay, Amazon, Ali express, Wish i mnoge druge, a u Hrvatskoj su to MojShop, Zena.hr, Neckermann, PauzaGo iako je to djelatnost dostave hrane svejedno je ujedno i web trgovina jer ljudi naručuju hranu preko nje te Hgspot koja je i stvarni dućan a i dućan preko interneta, ali bavi se prodajom isključivo tehnologije i informatičke opreme.

Internetske aukcije isto su jedan od popularnih načina prodaje proizvoda putem interneta. Funkcionira isto kao prava fizička dražba samo virtualno putem interneta, prodavatelj definira minimalnu cijenu te treba postojati sigurnost da neće doći do internetske prijevare koje znaju biti jako česte u današnje vrijeme. Zbog toga se koristi siguran način plaćanja a to je svima dobro poznati PayPal ili ako se radi o nekom većem iznosu onda kupac uplati određeni polog kao sigurnost da će plaćanje biti obavljeno od neke treće osobe kojoj vjeruju. Kupac uplaćuje novac na račun posrednika uz dogovor da posrednik plati robu tek nakon što kupac zaprimi robu koju je kupio.

2.2 Različite vrste i modeli elektroničkog poslovanja

Postoje različite vrste elektroničkog poslovanja koje poduzeća koriste na različite načine ovisno o vrsti djelatnosti koju provode. Te vrste elektroničkog poslovanja su:

1. Internetske tvrtke koju posluju samo putem interneta kao što su eBay ili Amazon
2. Tvrtke koje kombiniraju tradicionalne oblike poslovanja s internetskim informacijama kao šta je MSAN.hr
3. Tvrtke koje temelje svoje poslovanje na samom internetu poput proizvođača hardvera i softwera (Microsoft, Apple), telekomunikacijske tvrtke koje pružaju usluge pristupa internetu (T-com, Iskon, A1)
4. Tvrtke čija je osnovna djelatnost spajanje kupaca i proizvoda/usluga

Ranije su navedeni modeli elektroničkog poslovanja ili vrste elektroničke trgovine a sada će se svaki model pobliže objasniti.

1. Business to business (B2B) – poslovanje između dvije ili više tvrtki koji uz pomoć visokointegriranih sustava u potpunosti integriraju dobavljače s kupcima u smislu informacijsko-komunikacijske tehnologije.
2. Business to consumer (B2C) – poduzeće prodaje proizvode krajnjem korisniku, većinom građanu pojedincu, dakle radi se o maloprodajnim djelatnostima ili elektroničkoj trgovini. Poduzeća koja koriste ovaj model ima puno veći broj prodaja nego poduzeća koja prodaju proizvode drugim poduzećima.
3. Business to government (B2G i G2B) – poduzeća prodaju proizvode i usluge državnim tijelima
4. Consumer to consumer (C2C) – to su sve transakcije između građana pojedinaca, u prijevodu prodaja proizvoda jednog građana drugom u kojem često sudjeluju i treće osobe kada je riječ o internetskim aukcijama ili kada se proizvodi kupuju putem oglasa što je danas jako česta pojava

2.3 Prednosti i nedostaci elektroničkog poslovanja

Sve što postoji u ovom svijetu od raznih tehnoloških izuma, računalnih programa do raznih automobila, ima svoje prednosti i nedostatke ma koliko god se oni činili savšreni na prvi pogled. Isto tako i elektroničko poslovanje ima svoje prednosti i nedostatke koje će se navesti u nastavku.

2.3.1 Prednosti elektroničkog poslovanja

Internet je stvorio poslovno okruženje u kojem su vrijeme i udaljenost manje važni, ljudi imaju pristup većoj količini informacija koje im pomažu u donošenju odluka, a potrošači imaju bolji pristup širem rasponu proizvoda i usluga.[4] Sve više ljudi počinje kupovati proizvode i usluge na internetu zahvaljujući tehnologiji koja se koristi za uvođenje i provedbu elektroničkog poslovanja čime pomaže pronalaženje novih kupaca. Danas pogotovo svako ima pristup internetu i troškovi nisu veliki pa se ljudi više opuštaju u kupovinu preko interneta jer zašto bi odlazili u dućane čekali redove na blagajnama i gužvali se s puno ljudi kad kupovinu mogu obaviti sa svog naslonjača. Proizvode i usluge preko interneta moguće je kupiti u bilo koje vrijeme jer su trgovine online dostupne 24 sata dnevno, sedam dana u tjednu, 365 dana u godini pa ljudi ne moraju voditi brigu o radnom vremenu trgovine ako kojim slučajem ne stignu otići u dućan jer su imali drugih bitnijih obaveza. Važno je napomenuti kako kupovina preko interneta je uvijek jeftinija nego kupovina u fizičkom dućanu i dostava bude besplatna nakon što se premaši određeni iznos kupovine a većinom to bude oko 500 kuna. Za male i srednje poduzetnike isto ima dobrih prednosti elektroničko poslovanje. Odgovarajuće dizajnirane i oglašavane web stranice mogu privući nove kupce i otvoriti nova tržišta za proizvode i usluge, naprimjer omogućavanjem pristupa kupcima iz cijelog svijeta bez velikih troškova i nuđenjem pristupa proizvodima i uslugama za ljude s vrlo specifičnim interesima.[5] Puno je lakše preko interneta ispitati tržište, istražiti potencijalne konkurente te potražiti nove

[4] Ibid. Str. 26.
[5] Ibid. Str. 27.

strateške partnere. Pomoću elektroničkog poslovanja puno je lakše analizirati podatke o posjetiteljima na našoj stranici jer prema tim podacima poduzeća točno znaju što trebaju poboljšati, kakve proizvode posjetitelji najviše traže te na taj način postići maksimalan učinak za prodaju. Najbolji alat za iščitavanje podataka na web stranici elektroničke trgovine je Google Analytics, ali isto tako ima i još drugih manje poznatih programa za tu vrstu usluge.

2.3.2 Nedostaci elektroničkog poslovanja

Kod kupovine preko interneta, uvijek postoji rizik i kod kupca i kod prodavača od krađe podataka kreditnih kartica. Zbog toga uvijek treba izbjegavati nepoznate i sumnjive web lokacije koje vrlo često mogu biti neka vrsta prijevare, te koristiti sigurne i provjerene web stranice koje koriste sigurne načine plaćanja kao što su PayPal. Zbog tih razloga još uvijek postoji nedostatak povjerenja prema elektroničkom poslovanju jer ljudi strahuju da neće biti prevareni ili pokradeni za veću svotu novca koju poslije teško mogu povratiti nazad, makar u današnje vrijeme je sve manje takvih slučajeva jer je elektroničko poslovanje jako dobro zastupljeno na potrošačkim tržištima. Jedan od nedostataka je a to će uvijek biti nedostatak, nemogućnost fizičkog dodira proizvoda. To je posebno važno ako se radi o proizvodu kojeg je teško kupiti online prije nego se kupac uvjeri da li je to proizvod koji on traži. Primjer tome su odjeća i obuća, jer preko interneta nikad se ne zna da li će vam ta majica odgovarati, da li će vam to dobro stajati ili sa obućom isto tako. Isto tako je i sa naočalama, ima puno web stranica di ljudi mogu kupiti naočale ali teško je procijeniti koja veličina nam odgovara i koje naočale su najbolje za nas, sa time da uzmemo u obzir da naočale nisu nimalo jeftine pa ih je teško kupiti ako ne znamo da li će nam se sviđati.

3. Implementacija elektroničkog poslovanja i upravljanje poslovanjem malih i srednjih poduzetnika

Kod gotovo svih poduzeća danas implementacija elektroničkog poslovanja postala je gotovo neophodna stvar. Poduzeća danas razmjenjuju mnoštvo informacija s drugima, primaju i šalju puno podataka a to se posebno odnosi na prodaju u elektroničkoj trgovini. Čovjek danas više ne može kontrolirati sve informacije koje ulaze ili izlaze iz poduzeća, ili ako se radi o prodaji ne može pratiti sve narudžbe od korisnika i isto tako komuniciranje sa svakim korisnikom posebno. To bez elektroničkog poslovanja i umjetne inteligencije bi trajalo danima. Poduzeća iz tog razloga implementiraju elektroničko poslovanje te uz to implementiraju i dva informacijska sustava ovisno o njihovom izboru a to su sustav za upravljanje dokumentacijom ili sustav za planiranje resursa poduzeća (eng. Enterprise Resource Planning – ERP). Ta dva informacijska sustava omogućuju poduzeću lakše praćenje i kontroliranje podacima kojima raspolažu, pogotovo dokumentima vezani za prodaju kao što to mogu biti kupoprodajni ugovori na daljinu, narudžbe kojih danas preko interneta ima mnogo pa je to danas za čovjeka nemoguć posao. Gledajući samo jednu narudžbu tu već ima dosta dokumenata ovisno o kojem se proizvodu radi, može biti ugovor o kupoprodaji, otpremnice, izdavanje računa a sve to puno je lakše kada računalo radi za poduzeće odnosno kada mu pomaže u tome. Svi ti dokumenti pohranjuju se u bazu podataka i svaka izmjena se također sprema u bazu podataka. Kada poduzeća odluče implementirati ERP sustav ili ga implementirati uz sustav za upravljanje dokumentacijom, mora sadržavati opcije kao što su cjenici, ugovoreni cjenici, popusti, akcije, narudžbe kupaca, predračuni te evidencije uplata. To je jako bitno jer će poduzeće htjeti upravljati podacima koji se nalaze u elektroničkoj trgovini iz sustava koji već redovito ažurira na dnevnoj razini s novim podacima o cijenama, popustima ili akcijama. Kako bi se posjetitelji web stranice elektroničke trgovine mogli informirati o proizvodima, potrebno je određene podatke iz ERP sustava prikazati online. Ti podaci su naziv i šifra proizvoda, raspoloživa količina, cijena te opis i slika da posjetitelj vidi kako taj proizvod izgleda. Nakon toga velike su šanse da će posjetitelj na web stranici ako je našao proizvod koji ga zanima, postati i kupac. U nastavku, detaljnije će se objasniti kako ta dva informacijska sustava funkcioniraju te koje su njihove karakteristike.

3.1 Sustav za upravljanje dokumentacijom

Sustav za upravljanje dokumentacijom je računalni sustav koji se koristi za praćenje i spremanje elektroničkih dokumenata, te obično ima i mogućnost praćenja različitih verzija koje uređuju različiti korisnici.[6] Svako poduzeće ima programe kao što su Word, Excel i PowerPoint koji generiraju različite dokumente. No ti se dokumenti moraju stalno pohranjivati, pogotovo ako netko stalno te dokumente uređuje i stalno se iz ponova moraju pohranjivati nove verzije različitih dokumenata. Nakon nekog vremena više se ne zna koja je prava verzija dokumenata te postane iznimno teško ako ne i nemoguće u većim poduzećima to pratiti i nadzirati. Upravo zbog tog razloga postoji sustav za upravljanje dokumentacijom koji sve to radi umjesto čovjeka i olakšava mu rad. Funkcije sustava za upravljanjem dokumentacijom su sljedeće:

- označavanje i indeksiranje dokumenata
- katalogizacija
- pohrana
- uređivanje i praćenje verzija dokumenata
- pretraživanje
- dijeljenje i ispis dokumenata

Sustav za upravljanje dokumentacijom ima i svoj proces pomoću kojeg upravlja dokumentima a to je :

1. Unos dokumenata u sustav – skeniranjem ili izradom novih u alatima kao što su Word, Excel...
2. Pohrana i arhiviranje na način da se mogu pratiti verzije dokumenata
3. Alati za indeksiranje, dohvat i pretraživanje dokumenata
4. Distribucija za izvoz dokumenata iz sustava
5. Zaštita dokumenata od neovlaštenog pristupa
6. Praćenje izmjena

[6] Ibid. Str. 58.

Za sve te procese potreban je softver koji služi za upravljanje dokumentacijom, a to su M-Files i Microsoft SharePoint.

3.2 Planiranje resursa poduzeća (eng. Enterprise Resource Planning – ERP)

ERP ili planiranje resursa poduzeća je središnja aplikacija koja sadrži sve podatke tvrtke o svemu – proizvodima, partnerima, nabavi, logistici, računovodstvu, fakturiranju itd., te svi načelno imaju pristup svim podacima.[7] Ta aplikacija bude izrađena ili po narudžbi poduzeća ili bude isporučena kao licencni paket. Licencni paket sadrži softverske komplete kupljenje od proizvođača koji obuhvaćaju cijelo poduzeće, ali su izrađeni na modularan način, čime omogućuju poduzećima da prilagode sustav svojim specifičnim aktivnostima primjenjujući samo neke od tih modula.[8] ERP sustav ima i svoje karakteristike a to su:

- strukturiran za okruženje klijent servera
- integracija gotovo svih poslovnih procesa
- procesiranje većinu gotovih transakcija
- koristi bazu podataka koja samo jednom pohranjuje svaki podatak
- omogućuje pristup podacima u stvarnom vremenu

[7] Ibid. Str. 64.
[8] Ibid.

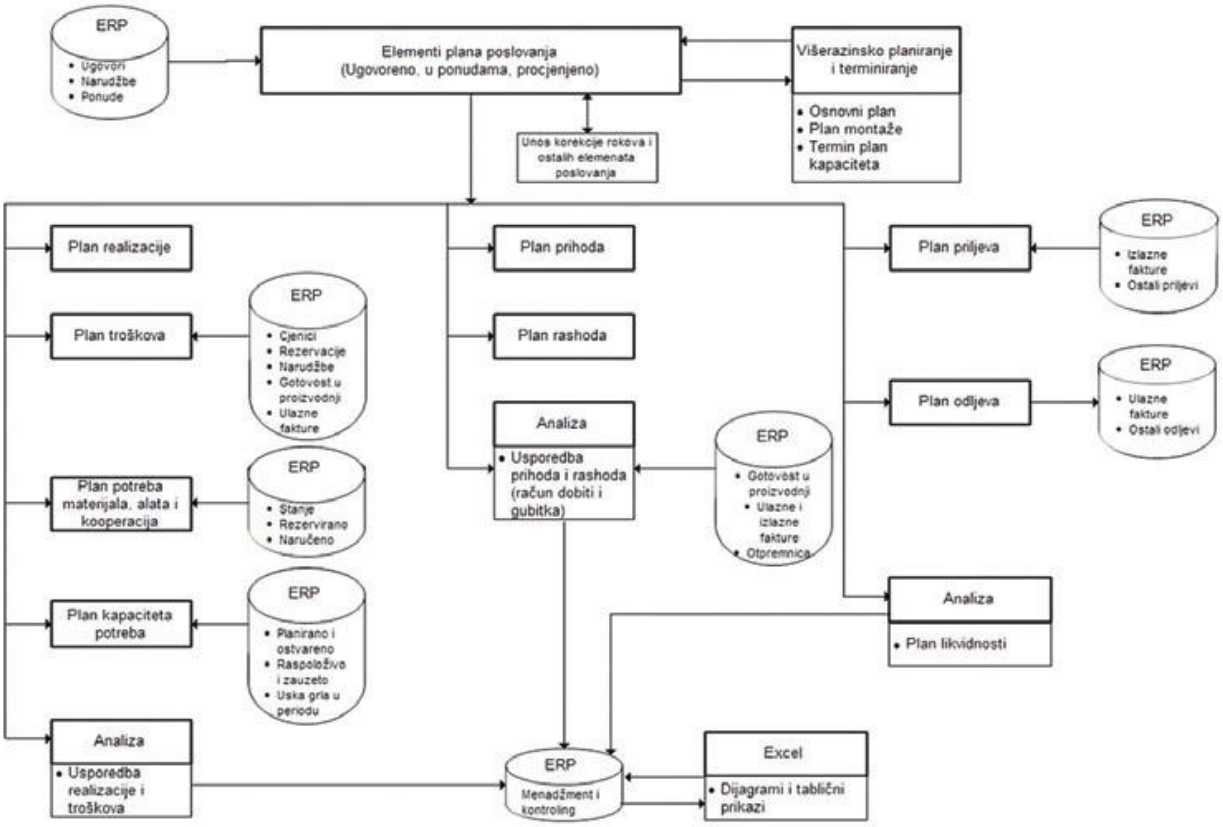

Slika 2. Primjer procesa ERP sustava

Izvor: http://www.infotrend.hr/clanak/2013/11/upravljanje-potencijalima-poduzeca,78,1028.html – 29.07.2020

Mali i srednji poduzetnici trebali bi imati ERP sustav u svojem poduzeću zbog toga što procesira sve poslovne aktivnosti u poduzeću te samim time olakšava posao svima u poduzeću jer ima manje papirologije i nepotrebne dokumentacije koju stalno treba pohranjivati itd. Također dovodi do smanjenja troškova u poduzeću te omogućuje praćenje i kretanje zaliha te stanja u poduzeću u svakom mogućem trenutku. ERP kao i sve ostalo ima također svoje prednosti i nedostatke. Prednosti su mu da su manji ukupni troškovi vlasništva, manje je rizik kod implementacije te je samim time i brža implementacija i vještina i stručnost dolazi iz vanjskih izvora. Nedostaci su mu nastajanje problema zbog sigurnosti podataka jer pružatelj usluge može kontrolirati podatke tvrtke, nije moguća prilagodba aplikacija te katkada aplikaciju treba integrirati s postojećim podacima korisnika a to može biti vrlo skupo i složeno.

4. Umjetna inteligencija

4.1 Što je umjetna inteligencija?

Pod umjetnom inteligencijom opisuju se umjetni, odnosno neživi sustavi koji pokazuju neki oblik “inteligencije”, odnosno snalaženja u novim okolnostima i uvjetima te uče na temelju iskustva i prikupljanja novih informacija. Istodobno, riječ je o području računalnih znanosti koje se bavi razvojem i proučavanjem takvih sustava te njihovom praktičnom primjenom.[9] Umjetna inteligencija prisutna je dugi niz godina a primjer tomu su društvene mreže kao Facebook koja je nastala još davne 2004. godine, Twitter, Instagram i mnoge druge. Ona prati naše aktivnosti na društvenim mrežama kao naprimjer tko je koga dodao kao prijatelja, tko je kome “lajkao” sliku i tako dalje, prepoznaje lica na fotografijama, određuje koji će se oglasi prikazivati određenim korisnicima s obzirom na njihova prethodna pretraživanja na internetu i njihove interese. Umjetna inteligencija danas je neophodna za ljudski život jer većinu toga što koristimo kao što su pametni telefoni, satovi, televizori, automobili i još puno toga, sve to se bazira na umjetnoj inteligenciji. Pogotovo kada se govori o automobilima, oni danas imaju toliku razvijenu tehnologiju da praktički umjetna inteligencija obavi skoro cijeli posao za vas, na vama je samo da sjedite i vozite a ide i prema tome da u budućnosti niti to neće biti potrebno jer će umjetna inteligencija voziti umjesto nas. U zdravstvu se također počinje primjenjivati umjetna inteligencija. Velik broj doktora danas za dijagnosticiranje bolesti (pretežito raka) koristi umjetnu inteligenciju koja im pomaže zatim u planiranju operativnih zahvata. Operativne zahvate još uvijek izvode doktori ali u budućnosti je sve izvjesnije da će i to provoditi umjetna inteligencija. Umjetna inteligencija je sadašnjost I budućnost ovoga svijeta.

4.2 Klasične metode u umjetnoj inteligenciji

Klasična umjetna inteligencija se zasniva na upotrebi simboličkog pristupa i metoda. Polazi od pretpostavke da se inteligentno ponašanje postiže razvojem sustava kroz logičko zaključivanje na temelju definiranog skupa pravila i činjenica – simbola.[10] Kod

[9] https://www.perpetuum.hr/sto-ai-zapravo-moze-i-sto-njegov-razvoj-znaci-za-developere 15.08.2020
[10] Kovač, L. (2015.) Umjetna inteligencija danas. Rijeka. Filozofski fakultet politehnike i informatike u Rijeci. Str. 15. Dostupno na: https://zir.nsk.hr/islandora/object/ffri%3A824 15.08.2020

klasične metode primjenjuje se TOP-DOWN pristup koji se temelji na znanju simboličkog opisa svijeta kroz definirani skup pravila. Ta metoda funkcionira na način da se problem podjeli na potprobleme u rekurzivnom smislu, a to je da se jedan veliki problem podjeli na više manjih, jednostavnijih problema. Klasični pristup funkcionira tako da se analizira rad mozga izvana (aktivnosti koje izvodimo svakodnevno) i onda na temelju te analize se pokušava replicirati njegov rad na umjetnoj inteligenciji.

4.3 Moderne metode u umjetnoj inteligenciji

Ova metoda se temelji na BOTTOM-UP dizajnu koja se odnosi na elementarna ponašanja koja se kombiniraju kako bi se ostvarila kompleksnija ponašanja. Moderna metoda zagovara da se kroz smještenost, odnosno kroz senzorne interakcije i motorne vještine može ostvariti inteligencija kod strojeva. Izraz smješten (engl. situated) nastao je u robotici i odnosio se na smještaj robota u okolini, međutim može se smatrati da se smještaj odnosi i na softverske agente pod uvjetom da se oni nalaze u dinamičkom okruženju, da svojim ponašanjem mogu manipulirati i mijenjati okruženje koje su u stanju osjećati i percipirati.[11] Ne oslanja se na simbolički opis svijeta već je naglasak više na kreiranje modela interakcije entiteta i njihove okoline. U interakciji s okolinom, inteligentno ponašanje entiteta postiže se kroz povezivanje jednostavnih procesnih elemenata koji rade paralelno poput neurona u mozgu. Na taj način funkcioniraju umjetne neuronske mreže pa se zbog toga ovaj pristup još zove i konektivistički pristup.

[11] Ibid. Str. 25.

5. Inteligentni agenti

5.1 Što su inteligentni agenti?

Inteligentni agenti predstavljaju računalni softver koji ima za sposobnost da fleksibilno, samostalno i bez intervencije korisnika izvršava postavljeni zadatak, a krajnjeg korisnika izvještava o završetku zadatka ili samoj pojavi događaja koji se očekuje.[12] Inteligencija je sposobnost inteligentnih agenata da prihvaćaju zadane ciljeve te da ih uspješno izvršavaju, te da održavaju razinu kvalitete razmišljanja i naučenog ponašanja. To su programske komponente koje imaju ulogu posrednika između korisnika i računala. Svi inteligentni agenti su temeljeni na umjetnoj inteligenciji, raspodijeljenom programiranju, internet tehnologiji te mobilnoj komunikaciji. Tri osnovne karakteristike inteligentnih agenata su da radi za svojeg korisnika, radi sa njegovom dozvolom te da su specijalizirani za određeno područje. Inteligentni agenti imaju još i druga imena a to su softverski agenti, vodiči, roboti znanja i softverski roboti. Agenti svoju okolinu percipiraju putem senzora i efektora. Ljudski agent ima oči, nos, uši za svoje senzore te ostale organe a pod efektore spadaju noge i ruke te usta jer pomoću njih izvodimo aktivnosti. Senzori kod robotskih agenata su skroz drugačiji od ljudskih što je i za očekivati, jer oni umjesto senzora imaju kamere i infracrvene lokatore a za efektore imaju različite motore. Kada je riječ o softverskom agentu, on koristi bitove za percipiranje okoline i za aktivnosti koje izvodi.

5.2 Struktura inteligentnih agenata

Svrha umjetne inteligencije je stvaranje agent programa koji implementira mapiranje agenta od percepta do akcije. Taj program će se izvoditi na nekoj vrsti računala koji se naziva arhitektura. To računalo može biti jednostavno ali može sadržavati i hardver za recimo obradu unesenih slika ili filtriranje i obrađivanje unesenog audio podatka. Ukratko rečeno, pomoću arhitekture program dobiva dostupne perceptore iz senzora, te efektorima dobavlja generirane programske akcije. Kada se zajedno ujedine arhitektura i

[12] https://hr.wikipedia.org/wiki/Inteligentni_agenti 16.08.2020

agent program nastaje inteligentni agent, pa možemo reći da je to građa jednog inteligentnog agenta.

5.3 Vrste inteligentnih agenata

Postoji pet vrsta inteligentnih agenata na temelju njihovog stupnja percipirane inteligencije i mogućnosti grupirani od strane Russella i Norviga:

1. jednostavni refleksivni agenti
2. refleksivni agenti temeljeni na modelu
3. agenti temeljeni na cilju
4. agenti temeljeni na korisnosti
5. učeći agenti

U nastavku će svaki od njih biti pobliže objašnjen kako bi se shvatilo na koji način svaki od njih funkcionira.

1. Jednostavni refleksivni agenti

Djeluju na temelju trenutne percepcije ignorirajući prethodne percepcije. Funkcioniraju na način stanje-akcija, ako se zadovolji određeno stanje ili određeni uvjet onda slijedi izvođenje akcije. Ta je funkcija primjenjiva samo ako je okolina u potpunosti primjetljiva. Neki refleksivni agenti mogu sadržavati informacije o njihovom trenutačnom stanju što im omogućava zanemarivanje uvjeta čiji su pokretači već pokrenuti.[13] Za agente koji rade u djelomično primjetljivim okolinama neizbježne su beskonačne petlje.

[13] https://hr.wikipedia.org/wiki/Inteligentni_agenti 24.08.2020

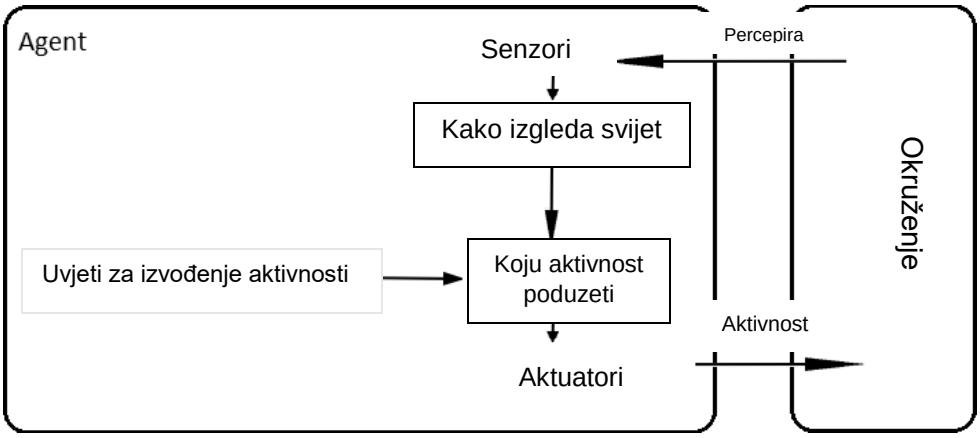

Slika 3. Primjer jednostavno refleksivnog agenta

Izvor: https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

Slika 3. prikazuje kako agent percipira utjecaje iz okruženja pomoću senzora, primjećuje svoju okolinu te ako postoje uvjeti za izvođenje aktivnosti on će je izvesti i primijeniti u njegovom okruženju.

2. Refleksivni agenti temeljeni na modelu

Ovi se agenti mogu nositi s djelomično primjetljivom okolinom jer je njihovo trenutačno stanje pohranjeno unutar agenta. Sadrže određenu vrstu strukture koja opisuje dio svijeta koji ne može biti viđen. Ovi agenti trebaju održavati neku vrstu internog modela koji ovisi o povijesti percepcije te održavati barem dio neprimjetnog aspekta trenutačnog stanja, pa onda odabire akciju na isti način kao i jednostavni refleksivni agent.[14]

[14] https://hr.wikipedia.org/wiki/Inteligentni_agenti 24.08.2020

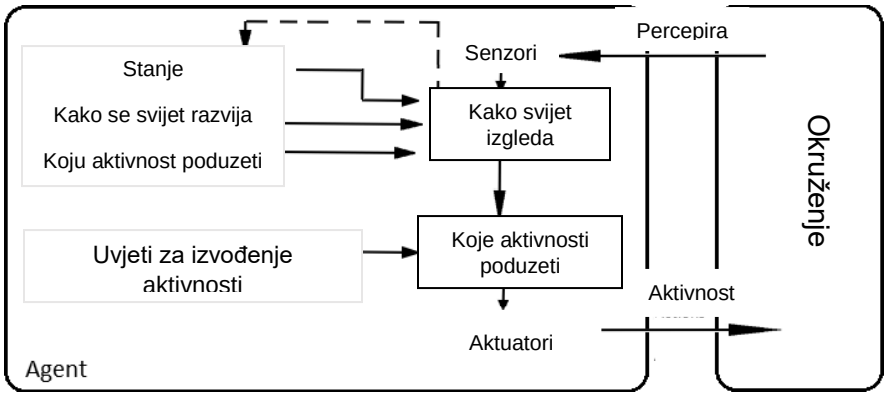

Slika 4. Primjer refleksivnog agenta temeljenog na modelu

Izvor: https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

Slika 4. prikazuje kako agent pomoću senzora percipira utjecaje iz okruženja te kako je njegovo stanje pohranjeno u njemu, i pomoću toga može vidjeti kako se svijet razvija odnosno može vidjeti svijet koji ne može biti viđen. Ima uvjete iz kojih odlučuje koju aktivnost izvesti.

3. Agenti temeljeni na cilju

Ovi agenti koristeći informacije o cilju, proširuju mogućnosti agenata temeljenih na modelu. Ta informacija pruža agentu mogućnost da bira između višestrukih mogućnosti, a on bira onu koja ispunjava ciljno stanje.

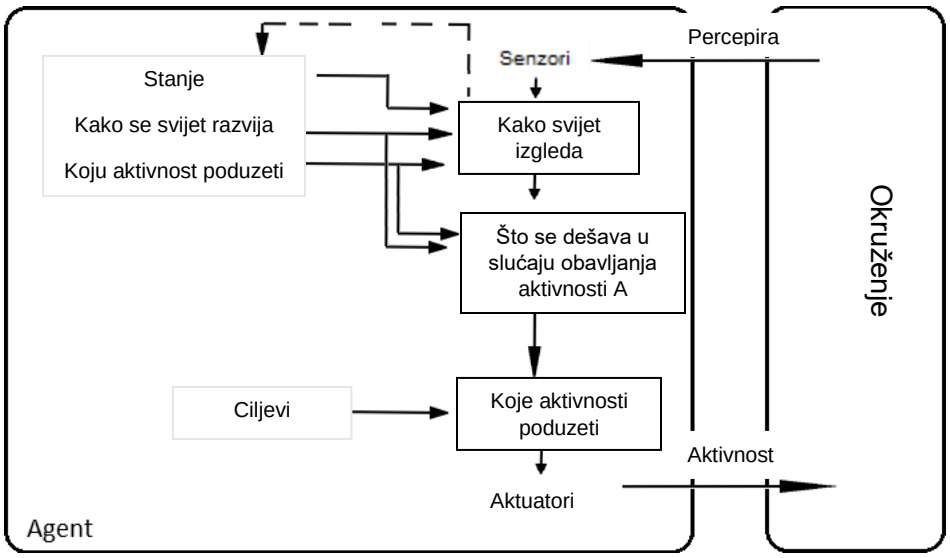

Slika 5. Primjer agenta temeljenog na cilju

Izvor: https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

Slika 5. prikazuje kako agent nakon što percipira utjecaje iz okruženja ima ponuđene brojne aktivnosti koje može izvesti, ali on izvodi onu aktivnost pomoću koje će ispuniti određene ciljeve koji su stavljeni pred njega.

4. Agenti temeljeni na korisnosti

Ovi agenti upotrebljavaju funkciju korisnosti pomoću koje definiraju mjeru kojom se mjeri poželjnost određenog stanja. Općenite performansne mjere omogućuju usporedbu različitih stanja svjetova prema načinu da se mjeri usrećenost agenta. Pojam “korisnost” opisuje koliko je agent “sretan”. Racionalni agent baziran na korisnosti odabire onu akciju koja maksimizira korisnost ishoda akcije.

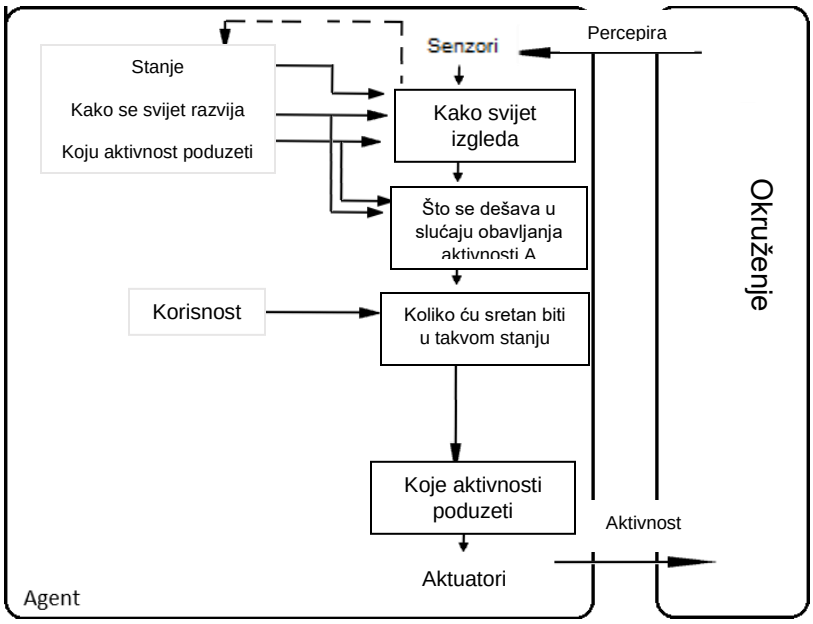

Slika 6. Primjer agenta temeljenog na korisnosti
Izvor: https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

Slika 6. prikazuje kako agent nakon što percipira utjecaje iz okruženja opet ima na raspolaganju različite aktivnosti koje može izvesti. Ovaj put bira aktivnost na temelju korisnosti, odnosno onu aktivnost koja će rezultirati kao najboljom mogućom jer će imati maksimalan učinak na okruženje.

5. Učeći agenti

Učenje ima prednost koja omogućuje agentu da inicijalno "radi" u nepoznatoj okolini te da postane kompetentan naspram njegovom inicijalnom znanju.[15] Jako je bitno znati razliku između elementa učenja i elementa performanse. Element učenja je odgovoran za poboljšanje dok je element performanse odgovoran za odabir eksternih akcija. Postoji komponenta koja se zove generator problema, koja je odgovorna za predlaganje akcija koje će se voditi prema novim i informativnim iskustvima.

[15] https://hr.wikipedia.org/wiki/Inteligentni_agenti 24.08.2020

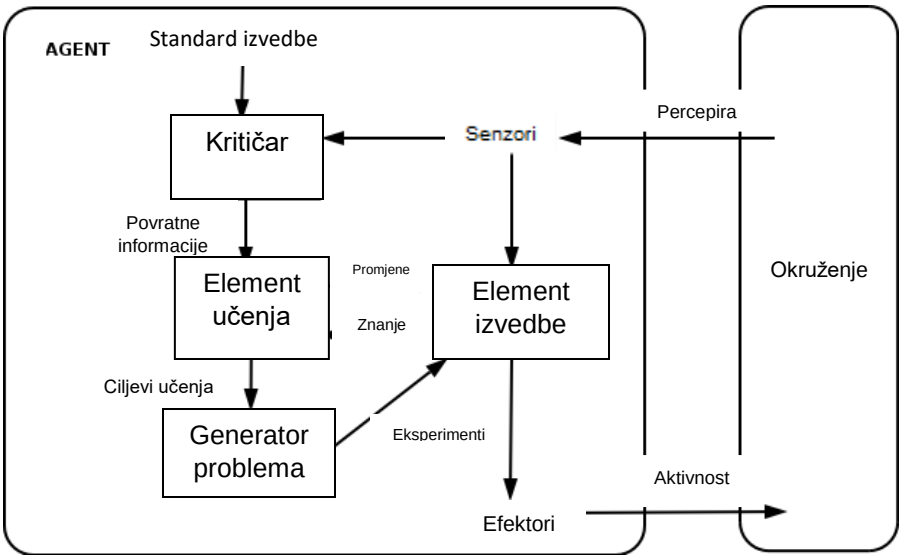

Slika 7. Primjer učećeg agenta

Izvor: https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

Slika 7. prikazuje kako agent percipira utjecaje iz nove ili nepoznate okoline. Nakon što te utjecaje percipira nastoji se učenjem prilagoditi toj okolini. Pomoću elementa učenja provodi promjene i poboljšanja u svojem znanju i svojim sposobnostima, a putem elementa izvedbe i efektora provodi aktivnosti u novo okruženje.

6. Primjena inteligentnih agenata

6.1 Primjena inteligentnih agenata u elektroničkom poslovanju

Elektroničke trgovine diljem svijeta imaju veliku količinu robe koju imaju na raspolaganju i koju prodaju, te upravo zbog toga postaje nemoguće pratiti sve narudžbe korisnika, njihove zahtjeve te potrebe koje imaju. Korisnici isto tako imaju problema jer ne mogu naći točan proizvod koji traže, ne znaju točno izraziti svoje zahtjeve, kakav proizvod točno traže i onda zbog toga dobiju izlistan velik broj proizvoda za koji većinom nisu zainteresirani jer to nije ono što oni traže. Zbog tih problema dolaze inteligentni agenti koji imaju mogućnost analizirati velike količine podataka, kategoriziraju proizvode tako da korisnici kad traže specifičan proizvod mogu tražiti pod točnim kategorijama i potkategorijama i tako odmah nađu proizvod koji ih zanima. Klasificiranje podataka o proizvodima i uspostavljanje modela korisnika je ključni koncept navigacije po informacijama proizvoda. Informacija o proizvodima mora biti potpuna i točna kako bi korisnici mogli ispravno voditi informacije, te poboljšati učinkovitost pretraživanja. Model korisnika bi trebao biti u mogućnosti održavati različite modele različitih korisnika te na taj način pružati personalizirane informacije različitim korisnicima. Sustav pruža korisnike sa znanstvenim znanjem i standardima, te kad korisnik sa druge strane upiše ključnu informaciju o proizvodu, agent pronađe u kojoj kategoriji ta ključna informacija pripada i na temelju nje ga usmjeri u pravom smjeru, točnije usmjeri ga prema proizvodima koje traži. Ako agent ne može pronaći kategoriju kojoj pripada ta ključna informacija, potražit će da li postoji neka slična kategorija kojoj bi ta ključna informacija mogla pripadati i pita korisnika za potvrdu da li je to ta kategorija koju on traži, te ako odgovor bude negativan onda traži od korisnika da navede točnu kategoriju proizvoda koju traži, odnosno kategoriju u kojoj bi se ta ključna informacija trebala nalaziti. Inteligentni agent će nakon toga proučiti ključnu riječ i informaciju i unijeti je u korisnički model, tako da sljedeći put kada korisnik pošalje upit će biti automatski poslan na kategoriju proizvoda kojeg on traži, te na taj način će se izbjeći ponavljanje prethodnih operacija.

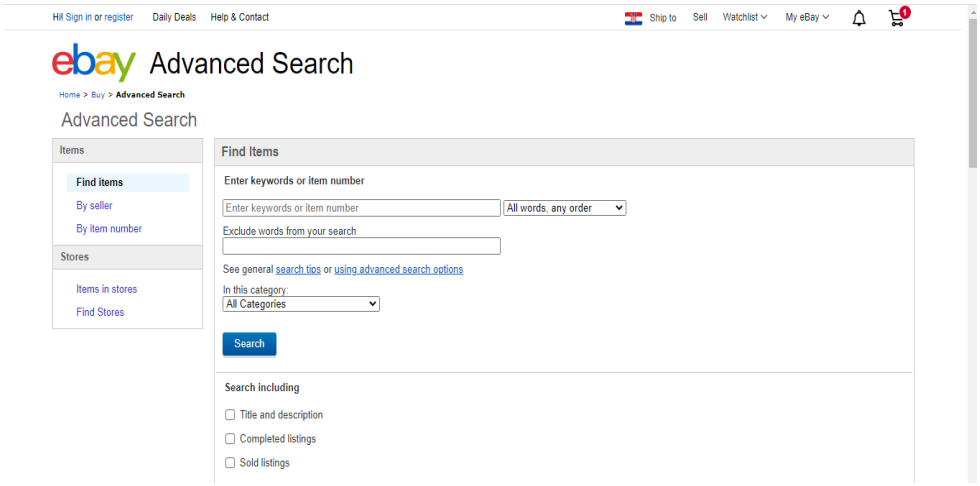

Slika 8. Primjer naprednog pretraživanja proizvoda na stranici eBay

Izvor: www.ebay.com – 01.09.2020

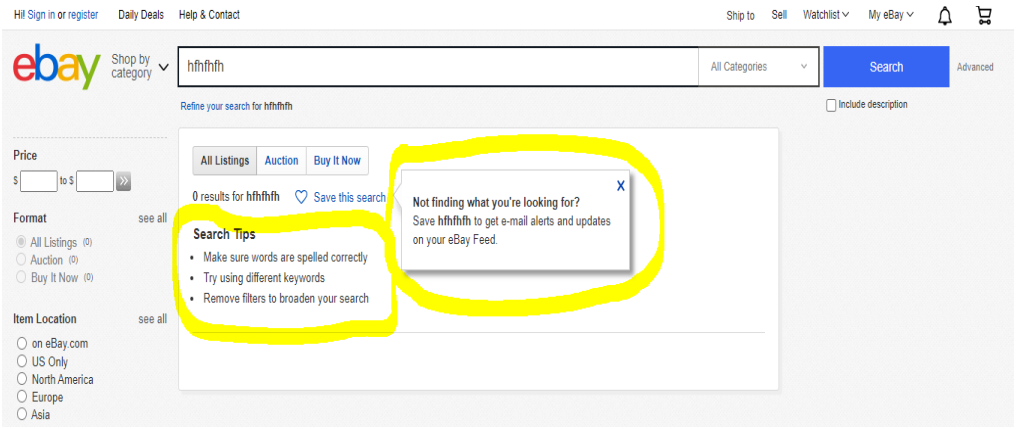

Slika 9. Primjer inteligentnog agenta koji nudi pomoć nakon utipkanog nepostojećeg pojma u bazi podataka eBay-a

Izvor: www.ebay.com – 01.09.2020

Slika 9. prikazuje kako agent nudi pomoć korisniku da provjeri da li je točno upisao riječ koju traži ili da pokuša tražiti proizvod pomoću druge slične ključne riječi. Također nudi mogućnost da korisnik spremi pojam koji je tražio pa će primiti e-mail poruku kada taj pojam budem bio u bazi podatak eBay-a, odnosno kada taj proizvod bude bio dostupan u fizičkom smislu ili pod tim imenom.

U sustavu elektroničke trgovine informacije o robama su dinamične i korisnici su na tu promjenu već naviknuti jer znaju da mogu očekivati takav ishod. Na temelju toga inteligentni agent ima mogućnost razvrstavanja pravila koja mogu sadržavati znanje iz izvornih podataka o robi i prema tim podacima dinamički generiraju web stranicu i kreiraju „user friendly“ sučelje za pregledavanje. Korisnici koriste ovo sučelje za interaktivnu komunikaciju te na taj način omogućuju inteligentnim agentima da pružaju bolju uslugu za kupce.

6.1.1 Inteligentno pretraživanje i filtriranje, te rješevanje problema preopterećenosti informacijama

Tradicionalna tražilica koristi isključivo ključnu riječ koja je unesena te ju podudara s ostalim sličnim upitima. Iz tog razloga može doći do suvišnih nepotrebnih informacija koje korisnika ne zanimaju, tu je potrebno filtriranje pretraživanja. Tu funkciju obavlja agent za filtriranje informacija. Nakon što taj agent dovrši posao filtriranja podatka on prema određenim pravilima za filtriranje i provjeru rezultata pretraživanja napokon korisnicima pruža rezultate prema redoslijedu prioriteta. Kod filtriranja informacija potrebno je razmotriti klasifikaciju podataka i filtrirati informacije u kombinaciji s korisnikovim modelom interesa, te pružiti korisnicima personaliziranu uslugu. Agent za filtriranje podataka pretvara način posjeta u način filtriranja kako bi filtrirao pretraživane informacije od strane korisnika, te na taj način pružio korisnicima točniji redoslijed rezultata pretraživanja, odnosno redoslijed po prioritetima korisnika. Nakon što korisnik odredi posebne potrebe kod informacija o proizvodu, inteligentni agent automatski otkrije i ažurira vijest, te ju pohranjuje u svoju bazu podataka. U isto vrijeme kad obavlja navedenu aktivnost, agent daje korisniku informacije u proizvodu. Na temelju toga možemo zaključiti kako su inteligentni agenti dosta fleksibilni te na kraju krajeva zato najviše i služe kako bi povećali fleksibilnost kod elektroničkih trgovina.

6.2 Inteligentni agenti za razgovor tijekom online prodaje

Inteligentni agenti za razgovor su vrsta tehnologije ili umjetne inteligencije koji imaju sposobnost da poboljšaju korisnikovo zadovoljstvo u širokom spektru primjena u

poslovnim poduzećima, obrazovanju, vladi, zdravstvu te čak i zabavi. Imaju mogućnost iskoristiti moć tehnologije prirodnog jezika za uključivanje korisnika u tekstualne informacije i orijentirane dijaloge. Uvođenje inteligentnih agenata za razgovor u maloprodajnim web trgovinama mogu dopustiti trgovcima da odgovore na upite kupaca za određeni proizvod ili uslugu. Takvi agenti dostupni su za korisnike 24/7, te su samim time i jeftiniji od zapošljavanja obučenog zaposlenika za call centre, chat uživo ili osobe koje odgovaraju na e-mail pošte. Web i računalna lingvistika je u globalu pokrenula rast inteligentnih agenata za razgovor. Raščlanjivanje unaprijed može dopustiti bolje razumijevanje ljudskog dijaloga koji je bio u obliku teksta. Korištenjem web tehnologije i računalne lingvistike, agenti za razgovor mogu tvrtkama ponuditi puno bolju korisničku uslugu nego kod tradicionalnih modela. Agenti za razgovor imaju i mogućnost pregovaranja tijekom online prodaje. Pregovaranje je jedno od važnijih aspekata u internet trgovini. U normalnoj situaciji pregovarački set jednaka je razlici između troškova koje ima prodavatelj i najviše cijene koju je kupac spreman platiti. U virtualnom okruženju je situacija nešto drugačija, jer pregovarački agent obično određuje njegovo djelovanje prema reakciji korisnika s druge strane. Glavna ideja je da agent za razgovor mora biti autonoman, proaktivan i racionalan. Autonoman mora biti zato jer mora obavljati aktivnosti bez ljudske intervencije jer je to i krajnji cilj inteligentnog agenta, proaktivan jer ne smije dopustiti da korisnici napuste internet trgovinu nego će ih uvijek pokušati navesti da nešto iz trgovine kupe i racionalni da mogu kupcu ponuditi odličnu i racionalnu ponudu koju bi on mogao prihvatiti.

6.2.1 Struktura inteligentnih agenata za razgovor

Inteligentni agenti za razgovor sastoje se od dvije glavne komponente, a to su upravitelj razgovora (dialog manager) i upravitelj baze podataka (database manager).

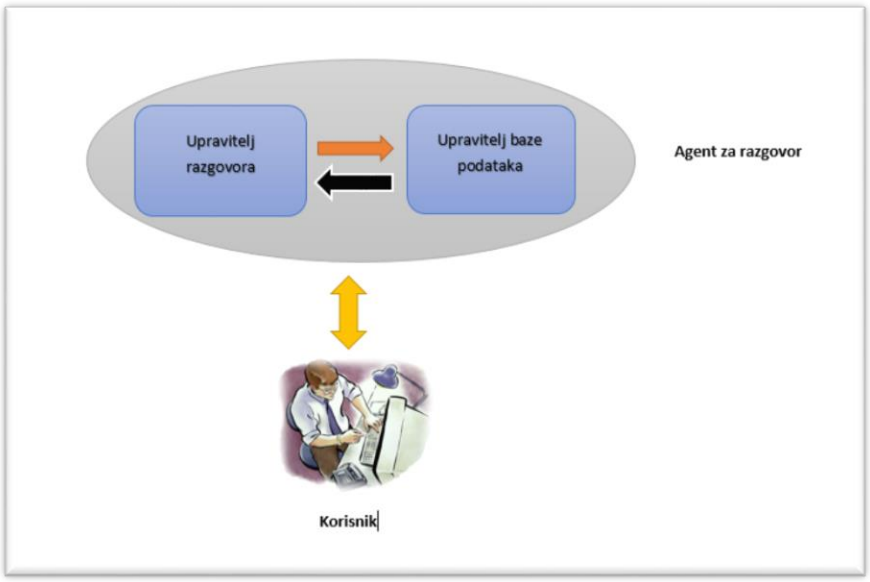

Slika 10. Struktura i komunikacija agenta za razgovor s korisnikom

Izvor: Autorsko djelo od Loris Cvek – 02.09.2020

Agenti za razgovor komuniciraju s kupcima na mreži kroz razgovor koji se sastoji od 6 vrsta dijaloga a to su pozdrav, namjera, upit, preporuka, pregovaranje i sporazum. Poruka dobrodošlice se pojavi kad internetska trgovina otkriva da postoji posjetitelj na web stranici jer se svaki posjetitelj internetske trgovine tretira kao potencijalni kupac. Glavni zadaci agenta za razgovor na internet stranici su sljedeći:

1. Izraziti dobrodošlicu korisniku
2. Saznati korisnikovu namjeru odnosno za koji je proizvod korisnik zainteresiran
3. Upitati korisnika o novčanom budžetu odnosno koliko je spreman platiti za proizvod
4. Predložiti mu ponudu u skladu s njegovim raspoloživim novčanim budžetom
5. Pripremiti alternativu ako korisnik odbije prvu ponudu
6. Zaključiti razgovor odnosno dogovoriti prodaju ponuđenog proizvoda

Upravitelj razgovora se sastoji od dva temeljna modula: sintaktički analizator i zadani dijaloški okviri. Sintaktički analizator odgovoran je za izvođenje prirodnih zadataka razumijevanja jezika, uključujući tokeniziranje teksta dijaloga i dodijeliti dio govora svakom tokenu pomoću POS-a (Part of speech) ili označivača dijelova govora. Jednom kada je svaki token označen s POS-om, vrši se prepoznavanje imenovanog entiteta te se izdvajaju proizvodi za kupca. *Upravitelj baze podataka* prima podatke od upravitelja razgovora, procesuira ih i obrađuje te natrag šalje obrađene podatke upravitelju razgovora. Glavne funkcije upravitelja baze podataka su:

1. Pretražiti tražene proizvode ako se nalaze u bazi podataka
2. Doznati cijenu za svaki traženi proizvod
3. Saznati koji je raspoloživi novčani budžet kod kupca
4. Pregledati ima li sličnosti traženi proizvod s proizvodom dostupnim u bazi podataka
5. Izračunati popust kako bi se kupcu mogla ponuditi povoljna ponuda

6.3 Ciljano oglašavanje korištenjem inteligentnih agenata

S obzirom na učinkovitost i troškove, inteligentni agenti su prikladni za web oglašavanje. Imaju važnu ulogu u elektroničkom poslovanju, pružaju pomoć u pretraživanju weba, pomoć u usporedbi potrošača i automatski obavještavaju korisnika o nedavnim događajima. Glavne njihove funkcije danas su pristup velikom broju informacija i navigacija kroz te informacije i podatke.

6.3.1 Čimbenici ciljanog oglašavanja i postupak istraživanja tržišta

Istražujući i proučavajući raspodjelu kupaca, možemo podijeliti cijelo tržište na nekoliko detaljnih tržišta. Tržišta se obično dijele na temelju ovih elemenata:

- demografski podaci
- psihografija
- geografski podaci

- bihevioralni podaci

Oglašivači prikupljaju podatke o kupcima putem različitih metoda, a svrha tog prikupljanja je da se kreira profil kupca, kako bi lakše mogli razumjeti što kupca najviše interesira. Oglašivači mogu oglas prilagoditi kupcima ili ih pitaju da li bi voljeli redovno primati informacije o proizvodu ili o nekim drugim povoljnim ponudama koje bi mogle imati veze s tim proizvodom. Ovaj navedeni posao, koji obavlja inteligentni agent, naziva se posredovanje. Informira kupce o novim proizvodima koji su tek stigli na tržište ili im preporučuje slične proizvode ili proizvode iz iste kategorije iz koje je zadnji put bila izvršena kupnja. Prodavač može naučiti nešto više o svojim kupcima i putem toga da vide što kupci traže na internetu, a ne samo što traže specifično na njihovoj stranici. U tu se svrhu baza podataka i alat za rudarenje podataka koristi za segmentiranje kupaca.

6.3.2 Model inteligentnog agenta za ciljano oglašavanje

Internetske stranice elektroničke trgovine uvijek imaju odgovarajuće kanale za korisnike kako bi oni mogli dobiti potrebne informacije. Ti kanali kreirani su zato da bi prodavač mogao poboljšati svoju strategiju prodaje proizvoda. Rudarenje podacima iz baze podataka danas tvrtkama omogućuje bolje oglašavanje na tržištu. Kako bi se mogao proučiti kupčev model kupovine, prvo se treba ispitati funkcija kataloga. Katalozi se koriste kako bi se moglo navigirati korisnika da dođe do željenog proizvoda ili željene web stranice u kojoj se nalazi proizvod kojeg namjerava kupiti. Za takve stvari su jako korisni interaktivni pametni katalozi koji se temelje na inteligentnim agentima. Oni se nalaze na webu, učinkoviti su i pružaju dodatne mogućnosti koje omogućuju da potencijalni kupci lociraju proizvode koje traže prema opisu njegovih specifikacija. Na taj se način korisnici brzo mogu usredotočiti na područje koje njih zanima i uštede si vrijeme, te imaju i personalizirani pregled također. Povezivanjem informacija o proizvodu s njegovim atributima kroz čitav distribucijski lanac, kupci mogu virtualne kataloge gledati u stvarnom vremenu te odmah vidjeti nove proizvode koji su tek stigli na tržište. Interaktivni pametni katalozi su savršena strategija za poboljšanje i olakšavanje kupnje potrošačima.

Slika 11. Primjer pametnog kataloga

Izvor: https://issuu.com/shimanoeuropefishing/docs/shimano2019_issuu_export - 03.09.2020

Slika 11. prikazuje primjer pametnog i interaktivnog kataloga. Upisalo se na njegovu tražilicu proizvod ili specifikacija proizvoda kojeg se traži i on odmah označi na kojim se stranicama taj proizvod ili ta specifikacija nalazi tako da je na donjoj traci označeno žutom bojom pa je dovoljno samo na nju kliknuti ili na gornjoj traci stisnuti strelicu za naprijed i on će automatski voditi na stranicu u kojima se nalazi to što se tražilo.

6.3.3 Skupljanje informacija i algoritam ciljanja

Kako bi se došlo maksimalnog učinka ciljanog oglašavanja, potrebno je podijeliti kupce u manje grupe kako bi se mogao izračunati njihov kupovni potencijal. Prilagođena stranica dobra je strategija da se sakupe detaljne informacije o korisnicima. Ako je korisnik registriran na stranicu, nakon što prilagodi svoju zadanu stranicu donoseći niz izbora, ta će mu se personalizirana stranica prikazati sljedeći put kada se prijavi. Kupci mogu dodavati, brisati ili uređivati stranice prema vlastitim interesima. Kod svake kategorije ima još niz potkategorija koje kupci mogu odabrati, pa će im se na stranici prikazivati oni proizvodi i sadržaji koji ih stvarno zanimaju. Svi ti odabiri korisnika se nakon toga

evidentiraju u bazi podataka. Zahvaljujući inteligentnim agentima, ove aktivnosti čovjek ne mora izvoditi jer je zapravo nemoguće i nezamislivo da ovo čovjek sve sam mora raditi. Zato je primjena inteligentnih agenata vrlo učinkovita i jeftinija te je atraktivna za korištenje. Trgovine kao što su Amazon, eBay, AliExpress koriste takve načine oglašavanja jer je puno lakše, brže i učinkovitije pogotovo jer su to velike trgovine sa milijardu proizvoda koje nude. Za provođenje ciljanog oglašavanja se koriste dvije metode. Prva metoda je prikupljanje podataka korisnika iz njegove registracije te njegove personalizirane izbore, te se na taj način njemu šalju prikladni oglasi. Kada korisnik bude ušao u svoju personaliziranu početnu stranicu, oglas će mu se pojaviti na okom upadljivom mjestu tako da ga neće moći izbjeći. Druga metoda je slanje e-mail pošte potencijalnim kupcima, koja sadrži ponude raznih proizvoda koje bi korisnika mogle zanimati. Kupci prilikom registracije na stranicu imaju izbor za odabrati da li su voljni dobivati e-mailove od prodavača ili ne.

6.4 B2C elektronička trgovina bazirana na inteligentnim agentima

B2C e-trgovina je vrsta elektroničke trgovine podijeljena prema predmetu trgovine odnosno koje proizvode trgovina prodaje (tehnika, drogerija, odjeća i obuća...), u specifičnom smislu to je internetska prodaja i uslužna elektronička trgovina između poduzeća i potrošača. Potrošači mogu koristiti računalo ili pametne telefone za izravan odabir proizvoda i eventualno preuzimanje robe. Prema različitom sadržaju proizvoda i usluge koje nude za kupce, B2C elektronička trgovina se može podijeliti u niz vrsta kao što su elektroničko posredovanje, mrežni marketing, elektronička maloprodaja, obrazovanje na daljinu, internetska zabava i internetske rezervacije. U B2C elektroničkoj trgovini, trgovačka uloga uglavnom uključuje poduzeća, potrošače, gateway za plaćanje, ovlašteno tijelo te pružatelj logistike.

6.4.1 B2C elektronička trgovina i inteligentni agenti

Sustav platforme za elektroničku trgovinu baziran na inteligentnim agentima pruža praktičniju i učinkovitiju uslugu kupcima i trgovcima, financijski je prihvatljiviji, poboljšava učinkovitost pretraživanja podataka, pruža inteligentno trgovačko okruženje i ostvaruje

mehanizam savjetovanja za elektroničku trgovinu kako bi agenti mogli raditi zajedno. Ova vrsta elektroničke trgovine bazirana na inteligentnim agentima sadrži troslojnu strukturu: korisnički sloj, aplikacijski sloj i sloj baze podataka. Korisnički sloj se uglavnom koristi za primanje zahtjeva i prenošenje zahtjeva na aplikacijski sloj. Stranica s povratnim informacijama sadrži datum prijave, korisničko sučelje za navigaciju, korisničko sučelje za prijavu te korisničko sučelje za kupovinu. Aplikacijski sloj se sastoji od agenta za pretraživanje proizvoda, agenta za preporučivanje proizvoda, agenta za kupnju proizvoda te agenta za pregovaranje. Glavna funkcija aplikacijskog sloja je interakcija sa slojem baze podataka prema korisnikovom upitu ili zahtjevu, prikaz rezultata, nakon enkapsulacije prikaz datuma, šalje te podatke u korisnički sloj te nakon toga dopušta korisniku pristup stranici. Sloj baze podataka uglavnom prima zahtjeve od svih agenata, bilježi podatke o korisnicima te ih sprema u bazu podatka i tako dalje istim procesom.

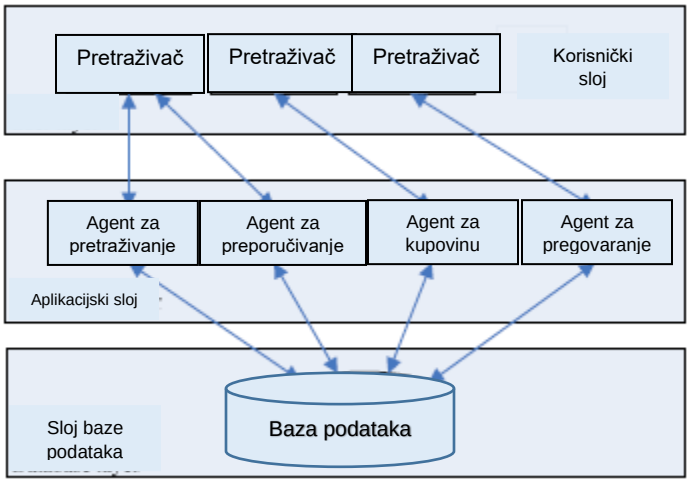

Slika 12. Dijagram funkcioniranja korisničkog, aplikacijskog i sloja baze podataka

Izvor: „W. Huang, J. Jin, L. Huang and W. Du, "Research on the B2C e-commerce based on Agent technique," 2010 2nd International Conference on Future Computer and Communication, Wuha, 2010, pp. V2-169-V2-172, doi: 10.1109/ICFCC.2010.5497365.“

Slika 12. prikazuje kako korisnik šalje upit agentu u elektroničkoj trgovini. Nakon što agent primi upit, šalje podatke o korisniku u sloj baze podataka kako bi se ti podaci pohranili, a korisniku uzvraća odgovorom putem različitih agenata ovisno o kojoj se vrsti upita radi.

6.4.2 Podsustavi inteligentnih agenata u B2C trgovini

Osim troslojne strukture, ova elektronička trgovina sastoji se i od tri podsustava a to su podsustav kupca, prodajni podsustav i CIC podsustav (informativni centar za klijente).

1. Podsustav kupca

Podsustav kupca sadrži dvije vrste agenta a to su agent za kupovinu i agent za klijente. Kupci se prijavljuju u podsustav kupaca putem preglednika i mogu obavljati osnovne operacije poput pretraživanja proizvoda, kupovine i modificiranje strategije kupaca. Agent za klijente bilježi proces transakcije i rezultate, grade vlastitu bazu znanja i dinamički mijenjaju model kupnje. Operativni postupci podsustava kupca su sljedeći:

- nakon sustava za prijavu korisnici automatski budu registrirani kod agenta CIC
- korisnici mijenjaju strategiju povećanja i brisanja prema njihovim potrebama
- na temelju korisničkih potreba, agent za klijente šalje upit agentu CIC, on pronalazi e-katalog, dobiva odgovarajuće informacije o proizvodima i pronalazi web stranicu prodavatelja te šalje te informacije klijentskom agentu a on ih onda šalje korisniku
- korisnici određuju broj trgovaca i web stranicu s kojom se žele savjetovati te onda šalju konačnu odluku klijentskom agentu
- na temelju rezultata i odluka klijentski agent generira broj agenata za kupnju koji će biti poslani na odgovarajuća web mjesta za daljnje konzultacije
- na temelju dobivenih rezultata klijentski agent će odlučiti koje su sljedeće akcije, ako je odbijen onda je agent za kupnju odmah otpisan, a ako primi pozitivne rezultate onda će klijentski agent obavijestiti korisnika o rezultatima i čekati korisničke upute. Tijekom tog procesa svi su rezultati pohranjeni u bazi podataka
- nakon zatvaranja transakcije klijentski agent otpisuje sve agente za kupnju i čeka korisnikove upute

2. Podsustav prodavatelja

Podsustav prodavatelja sadrži četiri vrste agenta: agent trgovine, agent za skladište, agent kontrole i agent prodavača. Korisnici u prodajni podsustav putem preglednika, obavljaju registraciju i opoziv robe, mijenjaju, brišu ili povećavaju prodavačevu strategiju. Agent trgovine bilježi proces transakcije i rezultate, gradi vlastitu bazu znanja i dinamički mijenja model prodaje. Operativni postupci prodajnog podsustava su sljedeći

- nakon prijave korisnika u sustav, sustav stvara agenta trgovine, tada trgovački agent stvara skladišnog agenta i agenta kontrole i automatski registrira CIC agenta
- na temelju potreba korisnici mijenjaju, dodaju i brišu strategiju prodavača
- prema potrebama korisnika, šalju se poruke CIC agentu, izmjenjuju, dodaju i brišu informacije o proizvodima
- nakon što korisnici odaberu proizvod, podatke šalju CIC agentu putem prodajnog agenta te se automatski pohranjuju svi podaci o procesu u bazu podataka
- na kraju trgovački agent šalje poruku CIC agentu da je usluga gotova, odnosno da je došao njezin kraj

3. Podsustav CIC

CIC agent koji se nalazi u podsustavu CIC, ekvivalentan je posredničkom agentu. Svaki sustav ima samo jedan CIC agent. Njegova glavna funkcija je pohranjivanje i upravljanje podacima trgovačkog i klijentskog agenta. Također mogu pružati savjetodavne usluge drugom agentu. Svi trgovački i klijentski agenti koji žele sudjelovati u procesu trgovine trebaju se registrirati u agentu CIC.

6.5 Inteligentni agenti u zdravstvu tijekom aktualne pandemije koronavirusa COVID-19

Tijekom aktualne pandemije koronavirusa umjetna inteligencija još jednom je pokazala svoju pozitivnu stranu u olakšavanju načina života u ovim teškim vremenima za čovječanstvo. Nakon malo više od mjesec dana od prvog slučaja koronavirusa u Kini, tehnološka industrija Huawei krenula je s implementacijom tehnološkog rješenja u svrsi

borbe protiv koronavirusa koja su se za Kinu ispostavila uspješnim. Uspjeh je postignut uz pomoć tehnologije koja je razvila Huawei industrija a to su 5G mreža, Huawei Cloud i umjetna inteligencija. Počeli su s implementiranjem Huawei Clouda pogonjenim umjetnom inteligencijom na 20 bolnica diljem Kine, a kako se ta implementacija pokazala uspješnom u prevenciji širenja koronavirusa, danas Huawei Cloud koristi više od 100 bolnica diljem svijeta. Ova tehnologija omogućila je čak šest puta brže dijagnosticiranje virusa u odnosu na vrijeme koje je uobičajeno potrebno liječnicima da utvrde virus. „Konkretno, liječniku je potrebno 12 minuta za dijagnostiku te dvije minute za pisanje nalaza, a upotrebom umjetne inteligencije dijagnoza je gotova u samo 10 sekundi, nakon čega je potrebna i dvominutna potvrda liječnika, te izrada nalaza za kojeg umjetnoj inteligenciji treba samo 30 sekundi" prenosi Huawei. U bolnice u Kini uvedena je 5G mreža koja je omogućila brzu razmjenu podataka te su na taj način liječnici mogli lakše komunicirati sa stručnjacima diljem svijeta. Zahvaljujući tome danas je stvorena baza podataka o koronavirusu koju koriste znanstvenici diljem svijeta kako bi lakše i što prije zaustavili ovu pandemiju. 5G mreža je također omogućila povezivanje psihologa koji su davali savjetovanja pacijentima teško pogođenim koronavirusom te posjete njihovih bližnjih putem video posjeta.

7. Zaključak

Primjena inteligentnih agenata u elektroničkom poslovanju učinila je elektroničku trgovinu neovisnijom, inteligentnijom i personaliziranom. Upravo zbog tog razloga danas se sve više kupovina odrađuje putem interneta jer je brže, jeftinije i učinkovitije. Zahvaljujući inteligentnim agentima, transakcijski troškovi su manji i za kupca i za prodavača a samim time transakcije su još učinkovitije. Agenti su korisniku olakšali doslovno sve od pretraživanja proizvoda, filtriranja informacija o proizvodu koje je korisnik naveo do ponude točnog proizvoda kojeg korisnik traži i to sve u jako kratkom vremenu. Pregovaraju s korisnicima oko razno raznih ponuda vezano za proizvode koje traže trudeći se uvijek ponuditi im najbolju moguću ponudu. Kada govorimo o prodavačima, agenti su njima također dosta olakšali cjelokupan posao pogotovo što se tiče oglašavanja i privlačenja korisnika da postanu njihovi kupci. Agenti za oglašavanje nude obećavajuću perspektivu u budućnosti cjelokupnog elektroničkog poslovanja te će sigurno sve više stranica koristiti takvu vrstu oglašavanja. Na kraju svega može se samo reći da je funkcioniranje današnjeg svijeta postalo nemoguće da nema tehnologije i umjetne inteligencije. Koliko god ljudi komentirali kako je tehnologija uništila svijet i učinila ga kompliciranijim, nema niti jedne funkcije, niti jednog posla danas a da ne koristi tehnologiju za obavljanje te funkcije ili tog posla.

POPIS LITERATURE

KNJIGE:

1. BEGOVIĆ, S. i PENIĆ, S. (2014.) *Poslovanje.* Zagreb. Ministarstvo poduzetništva i obrta

2. NADRLJANSKI, M. i NADRLJANSKI, Đ. (2016.) *Elektroničko poslovanje.* Zagreb. Redak

3. DUKIĆ, S i DUKIĆ, B. (2018.) *Uvod u elektroničko i mobilno poslovanje.* Koprivnica. Sveučilište Sjever

INTERNETSKI IZVORI:

1. https://www.mingo.hr/page/kategorija/e-trgovina - 26.07.2020

2.http://www.infotrend.hr/clanak/2013/11/upravljanje-potencijalima-poduzeca,78,1028.html – 29.07.2020

3.https://www.perpetuum.hr/sto-ai-zapravo-moze-i-sto-njegov-razvoj-znaci-za-developere – 15.08.2020

4. Kovač, L. (2015.) Umjetna inteligencija danas. Rijeka. Filozofski fakultet politehnike i informatike u Rijeci.

https://zir.nsk.hr/islandora/object/ffri%3A824 – 15.08.2020

5. https://hr.wikipedia.org/wiki/Inteligentni_agenti - 24.08.2020

6. www.ebay.com – 01.09.2020

7. W. Huang, N. Wang, J. Jin and F. Wang, "Technology and Application of Intelligent Agent in Electronic Commerce," 2010 International Conference on Measuring Technology and Mechatronics Automation, Changsha City, 2010, pp. 730-733, doi: 10.1109/ICMTMA.2010.140.

https://ieeexplore.ieee.org/document/5458995 - 28.08.2020

8. S. Jusoh, "Intelligent Conversational Agent for Online Sales," 2018 10th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Iasi, Romania, 2018, pp. 1-4, doi: 10.1109/ECAI.2018.8679045.

https://ieeexplore.ieee.org/document/8679045 - 01.09.2020

9. S. Liu and P. Liu, "Targeted Advertising Based on Intelligent Agents in e-Commerce," 2009 International Conference on E-Business and Information System Security, Wuhan, 2009, pp. 1-4, doi: 10.1109/EBISS.2009.5138100.

https://ieeexplore.ieee.org/document/5138100 - 02.09.2020

10. W. Huang, J. Jin, L. Huang and W. Du, "Research on the B2C e-commerce based on Agent technique," 2010 2nd International Conference on Future Computer and Communication, Wuha, 2010, pp. V2-169-V2-172, doi: 10.1109/ICFCC.2010.5497365.

https://ieeexplore.ieee.org/document/5497365 - 03.09.2020

11.https://issuu.com/shimanoeuropefishing/docs/shimano2019_issuu_export-
03.09.2020

12. https://www.ictbusiness.info/vijesti/umjetna-inteligencija-omogucava-sest-puta-brzu-dijagnostiku-koronavirusa - 04.09.2020

POPIS SLIKA

Slika 1. Vrste elektroničkih trgovina po sudionicima u transakcijama 3

Slika 2. Primjer procesa ERP sustava 10

Slika 3. Primjer jednostavno refleksivnog agenta …… 15

Slika 4. Primjer refleksivnog agenta temeljenog na modelu …….. 16

Slika 5. Primjer agenta temeljenog na cilju ……... 17

Slika 6. Primjer agenta temeljenog na korisnosti 18

Slika 7. Primjer učećeg agenta 19

Slika 8. Primjer naprednog pretraživanja proizvoda na stranici eBay 20

Slika 9. Primjer inteligentnog agenta koji nudi pomoć nakon utipkanog nepostojećeg pojma u bazi podataka eBay-a 21

Slika 10. Struktura i komunikacija agenta za razgovor s korisnikom 24

Slika 11. Primjer pametnog kataloga 27

Slika 12. Dijagram funkcioniranje korisničkog, aplikacijskog i sloja baze podataka 29

SAŽETAK

Na početku samog rada objašnjeno je što je to elektroničko poslovanje kako bi ga se pobliže upoznalo. U prvoj lekciji kao što je navedeno, objašnjeno je što je elektroničko poslovanje, kako ono funkcionira, zašto je danas elektronička trgovina toliko napredovala i toliko popularna. Navedene su vrste elektroničkog poslovanja te koje su prednosti i nedostaci elektroničkog poslovanja. Druga lekcija govori o implementaciji elektroničkog poslovanja u mala i srednja poduzeća, zašto bi je poduzeća trebala implementirati te koje koristi imaju od toga. Opisan je sustav za upravljanje dokumentacijom te ERP sustav ili kako poduzeća upravljaju svojim resursima. Treća lekcija govori o umjetnoj inteligenciji, što je to umjetna inteligencija, kako ona funkcionira, te su navedene klasične i moderne metode umjetne inteligencije. O inteligentnim agentima se počinje govoriti u četvrtoj lekciji gdje je objašnjeno što su to inteligentni agenti, koja je njihova struktura te kakvi inteligentni agenti postoje i svaki od njih je pobliže objašnjen. Peta i ujedno zadnja a i glavna lekcija govori o primjeni inteligentnih agenata u elektroničkom poslovanju. Govori o tome kako oni funkcioniraju u elektroničkom poslovanju, kako olakšavaju kupovinu kupcima i posao prodavačima. Navedeni su agenti za razgovor tijekom online prodaje te agenti za ciljano oglašavanje u elektroničkom poslovanju. Također je objašnjeno kako agenti funkcioniraju u B2C elektroničkoj trgovini a za sam kraj rad se nadovezuje na to kako inteligentni agenti pomažu zdravstvu u borbi protiv aktualne pandemije koronavirusa COVID-19.

Ključne riječi: elektroničko poslovanje, umjetna inteligencija, inteligentni agenti, prodaja

SUMMARY

At the beginning of this thesis, it is explained what is e-business in order to get to know it better. In the first lesson, as mentioned, it's explained what e-business is, how it works, why e-commerce is so advanced and so popular today. There are listed and explained what are the types of e-business and what are the advantages and disadvantages of e-business. The second lesson talks about the implementation of e-business in small and medium enterprises, why companies should implement it and what benefits they get from it. Also is described the document management system and the ERP system or how companies manage their resources. The third lesson talks about artificial intelligence, what artificial intelligence is, how it works, and after that are listed classical and modern methods of artificial intelligence. The fourth lesson talks about intelligent agents, there is explained what intelligent agents are, what is their structure and what types of intelligent agents there are and each one of them is explained. The fifth and at the same time the last and main lesson is about the application of intelligent agents in electronic business. It talks about how they work in e-business, how they make it easier for buyers to buy and for sellers to sell products. It's explained what are conversational agents during online sales and targeted advertising agents in e-commerce. It's also explained how agents work in B2C e-commerce and for the very end it's mentioned that intelligent agents are helping the public in the fight against the current coronavirus pandemic COVID-19.

Key words: electronic commerce, artifical intelligence, intelligent agents, sale