UPOTREBA UMJETNE INTELIGENCIJE U MARKETINGU

Kovačić, Leonard

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:540362

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Sveučilište u Zagrebu

Ekonomski fakultet

Stručni studij poslovne ekonomije, smjer Trgovinsko poslovanje

UPOTREBA UMJETNE INTELIGENCIJE U MARKETINGU

Završni rad

Kovačić Leonard

Zagreb, lipanj, 2020.

Sveučilište u Zagrebu

Ekonomski fakultet

Stručni studij poslovne ekonomije, smjer Trgovinsko poslovanje

UPOTREBA UMJETNE INTELIGENCIJE U MARKETINGU

APPLICATION OF ARTIFICIAL INTELLIGENCE IN MARKETING

Završni rad

Student: Kovačić Leonard, 0067576984

Mentor: prof. dr. sc. Mirko Palić

Zagreb, lipanj, 2020.

Ime i prezime studenta/ice

Leonard Kovačić

IZJAVA O AKADEMSKOJ ČESTITOSTI

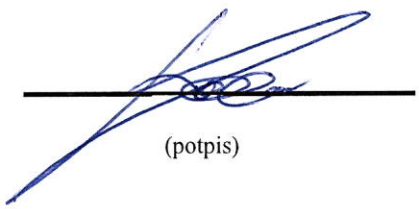
Izjavljujem i svojim potpisom potvrđujem da je ZAVRŠNI RAD

(vrsta rada)

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Student/ica:

U Zagrebu, 16.06.2020



(potpis)

1. UVOD 2
2. UMJETNA INTELIGENCIJA 4
2.1. Definicija i područja umjetne inteligencije 4
2.2. Primjena umjetnih neuronskih mreža unutar umjetne inteligencije 8
2.3. Primjeri upotrebe umjetne inteligencije u poslovanju 10
3. MARKETING 13
3.1. Pojmovno određenje marketinga 13
3.2. Marketinški koncepti i strateški pristupi u marketingu 14
3.3. Trendovi u digitalnom marketingu 17
4. UMJETNA INTELIGENCIJA U MARKETINGU 20
4.1. Uloga umjetne inteligencije u privlačenju, uvjeravanju i zadržavanju kupaca 20
4.2. Alati za primjenu umjetne inteligencije u marketingu 25
4.3. Uloga i pozicija ljudi u primjeni umjetne inteligencije u marketingu 27
4.4. Etički aspekt korištenja umjetne inteligencije u marketingu 29
4.5. Budućnost umjetne inteligencije u marketingu 31
5. ZAKLJUČAK 35
LITERATURA 37
POPIS SLIKA 40
POPIS TABLICA 40

1. UVOD

Živimo u razdoblju dubokih promjena vođenih digitalizacijom, informacijama i komunikacijskom tehnologijom, umjetnom inteligencijom, strojnim učenjem i robotikom. Poslovanje u tom kontekstu kojeg karakterizira cirkulacija obilja podataka uz istovremenu i potrebu tretiranja sve te količine podataka čini se nemogućim bez računala. U mnoštvu tih podataka umjetna inteligencija može uvelike olakšati analizu tih podataka, stvaranje prediktivnih analiza i mogućnost donošenja odluka na temelju upravo tih podataka.

Zbog toga se tradicionalni marketing sve više prebacuje na digitalni marketing koji omogućuju umjetnu inteligenciju i strojno učenje. Naime, umjetna inteligencija je, već danas, prisutna u svim komponentama marketinškog mixa. Umjetna inteligencija može povećati učinkovitost strategija tako što segmentira publiku, pomaže u personalizaciji i boljoj komunikaciji s klijentima te upravlja reklamnim kampanjama. Također, mnoga poduzeća koriste umjetnu inteligenciju za pisanje vijesti ili članaka, pa tako umjetna inteligencija može biti korisna i učinkovita u privlačenju posjetitelja na web stranicu organizacije stvaranjem sadržaja na određenim područjima. Osim toga, upravo u potrazi za segmentiranjem, personaliziranjem i automatizacijom procesa s klijentima, nastali si i virtualni pomoćnici- Chatbotovi koji pomaže poduzećima otkriti najčešće pitanja koja njihovi korisnici imaju o proizvodu ili usluzi, bez potrebe za ljudskom intervencijom.

Razvoj umjetne inteligencije se razvija i korak dalje: ona će proučiti učinak svake akcije prema korisniku, kao i njegove aktivnosti i reakcije, te će tako minimizirati nerelevantno oglašavanje, što će omogućiti korisniku da prati oglase koji ga doista zanimaju. Pri tome će, zbog optimalne personalizacije, korisnik osjetiti da ga organizacija poznaje i da nastoji udovoljiti njegovim potrebama.

Promjene nastaju i u fizičkim prodavaonicama gdje se automatski broji ljude koji ulaze trgovinu, identificira se ih putem mobilnih uređaja, bilježeći njihova kretanja i ponašanja obogaćuju podatke koje već imaju o njima.

Na taj način umjetna inteligencija posjeduje algoritme kojima se s velikom preciznošću mogu predvidjeti kupoprodajne akcije klijenata i njihove buduće aktivnosti, a kada je

poznato što klijenti traže, to uvelike olakšava pokretanje reklamne kampanje i procesa prodaje.

Uključivanje umjetne inteligencije u svijet marketinga omogućava brže postizanje boljih rezultata, oslobađajući veliki dio vremena za one koji se bave ponavljajućim zadacima s malo dodane vrijednosti. Tako će se marketinški timovi moći usredotočiti na inovacije i kontinuirano poboljšavanje primijenjeno na njihove kampanje .

Iako trgovci prepoznaju vrijednost koju tehnologija može pružiti, često im nedostaje optimalna kombinacija ljudskih resursa, organizacijske sposobnosti i tehnologije za učinkovito provođenje strategija umjetne inteligencije. Upravo iz tog razloga, ovim radom se želi ispitat mogućnosti i dosezi umjetne inteligencije u marketingu, kao i mogućnosti njezine upotrebe u svrhu poboljšanja prodaje, boljeg potrošačkog iskustva i povećanja zadovoljstva kupaca. Na taj način će se ovim radom nastojati ponuditi dublje razumijevanje uporabe i utjecaja umjetne inteligencije u marketingu.

2. UMJETNA INTELIGENCIJA

2.1. Definicija i područja umjetne inteligencije

Umjetna inteligencija je „dio znanosti o računalima koja se bavi projektiranjem inteligentnih računalnih sustava koji predočavaju karakteristike koje povezujemo s inteligencijom u ljudskom ponašanju". Tijekom evolucije ljudski mozak poprimio je niz karakteristika koje se povezuju s inteligencijom. Neke od karakteristika ljudi koji se povezuju s inteligencijom su: „paralelno odvijanje više operacija, sposobnost učenja, sposobnost generaliziranja (uopćavanja), sposobnost prilagođavanja, suvislo postupanje s informacijama, tolerancija na pogreške i nepotpune informacije" [1].

Iz navedenog se može zaključiti da bi se nešto moglo nazvati umjetnom inteligencijom, ono mora biti u mogućnosti izvršavati zadatke koji zahtijevaju određenu formu i razinu inteligentnog ponašanja u smislu kolokvijalne definicije inteligencije koja pod tim pojmom podrazumijeva snalaženje u novonastalim situacijama, pri čemu treba biti u stanju prepoznati i razumjeti ljudski jezik, te imati sposobnost učenja i zaključivanja. Pojam umjetne inteligencije sam po sebi se odnosi na tvorevine koje su proizvod ljudskog djelovanja, najčešće računalne sustave, a koji pokazuje inteligenciju. Pri tome su ti sustavi najčešće usko specijalizirani na neke funkcije i po tome se razlikuju od pojma ljudske inteligencija koja, iako ima neka svoja uža područja primjene, je ipak širi pojam. Funkcije inteligentnoga sustava jesu: „prikupljanje i obradba informacija, interakcija s radnom okolinom, komunikacija s čovjekom ili s drugim inteligentnim sustavima, prikupljanje i obradba znanja, zaključivanje, te planiranje." U tom smislu, pod umjetnim inteligentnim sustavom se podrazumijeva sustav koji je u mogućnosti učiti na temelju iskustva, prilagoditi se komunicirati s čovjekom prirodnim jezikom isl. [2]

Umjetna inteligencija (UI, engl. Artificial Inteligency) je kao zaglavnu kamen uključena u sve gradivne elemente 4. industrijske revolucije, a to su[3]:

- Robotika
- Nanotehnologija
- Internet stvari (IoT)
- Autonomna vozila
- Kvantna računala

[1] Ujević Andrijić, Ž. (2019). Osvježimo znanje, Kem. Ind. 68 (5-6) (2019) 219–220. str.219
[2] Leksikografski zavod Miroslav Krleža. Hrvatska enciklopedija. dostupno na: https://www.enciklopedija.hr/ (01 02.2020)
[3] Prister, V. (2019). Umjetna inteligencija. Media, Culture and Public Relations, 10, 2019, 1, 67-72. str. 67

- 3D tisak

Nastavno na sve navedeno, karakteristike inteligentnih računalnih sustava su[4]:

1. Inteligentni računalni sustavi se ponašaju usmjereno prema cilju pri čemu imaju sposobnost prilagodbe na način da u slučaju pogreške traži drugi put prema konačnom cilju pri tome je sposobno podijeliti glavni cilj na manje podciljeve, te upotrebom znanja prevode željeni cilj u slijed akcija.

2. Inteligentni računalni sustavi uči na temelju vlastitog iskustva. Pomoću posebno razvijenih algoritama inteligentni računalni sustavi mogu prikupljati podatke, obrađivati ih i pretvarati ih u informacije i znanje, te modificirati strukture i funkcije na temelju iskustva koja stječe u radu.

3. Inteligentni računalni sustavi koriste velike količine znanja i to u tolikoj mjeri da količina znanja u sustavu mora biti slična količini znanja koja bi bila potrebna čovjeku da riješi isti problem.

4. Inteligentni računalni sustavi pokazuju svojstva svjesnosti koji se materijalizira kroz sposobnost sustava da objasni svoje ponašanje, nadgleda i dijagnosticira stanja, te se oporavi u slučaju pogreške.

5. Inteligentni računalni sustavi posjeduju sposobnost komunikacije sa čovjekom prirodnim jezikom i govorom, a što uključuje i komunikacija obradu dvosmislenih i gramatički neispravnih rečenica.

6. Inteligentni računalni sustavi dozvoljava pogreške i nejasnoće u komunikaciji.

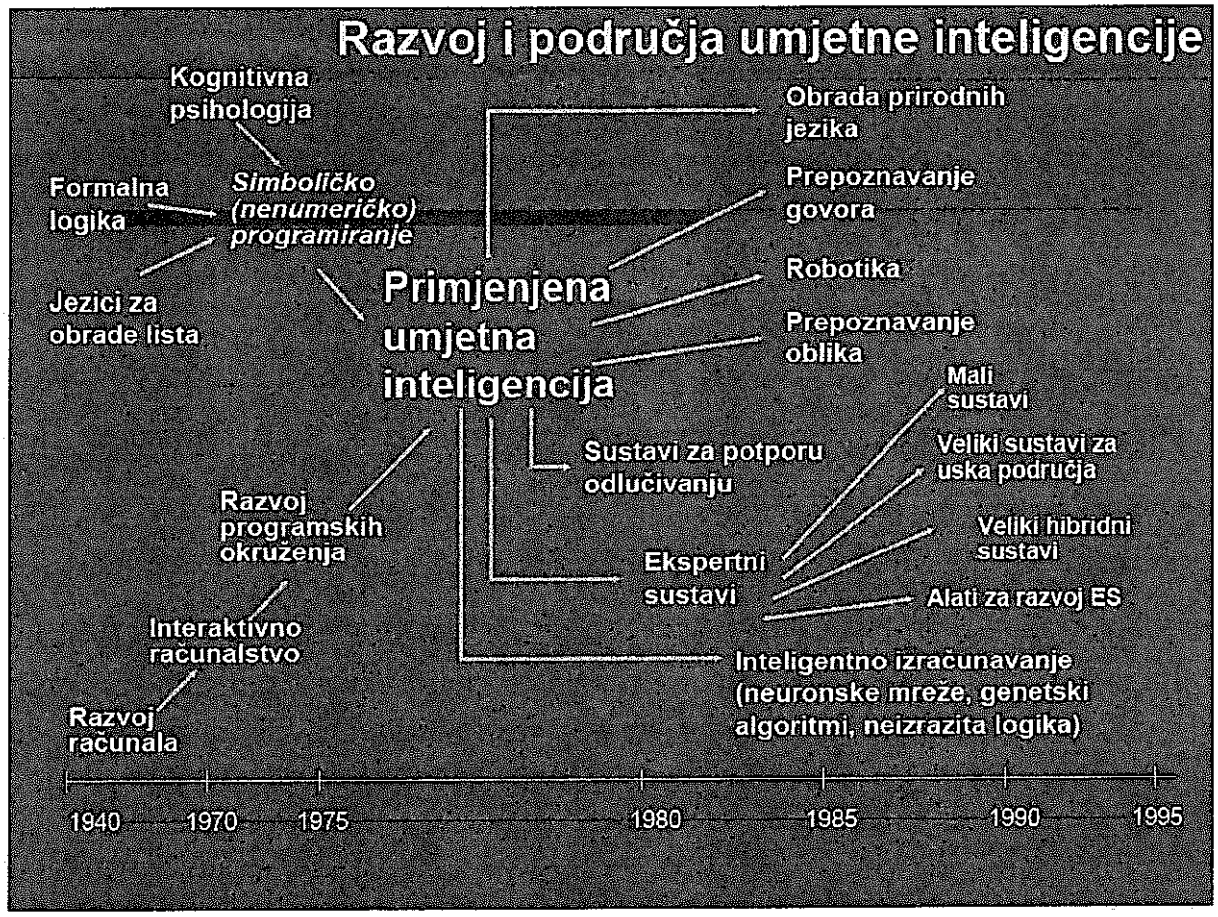
7. Inteligentni računalni sustavi odgovaraju u realnom vremenu.

Primjena umjetne inteligencije se ostvaruje u različitim područjima. Ta područja uključuju: „sustave za potporu u odlučivanju, inteligentno pretraživanje podataka, ekspertne sustave, formalizme i metode prikaza znanja, rješavanje problema i metode pretraživanja, učenje korištenjem primjera, razumijevanje i obrada prirodnih (i umjetnih) jezika,automatsko programiranje, računalni vid, raspoznavanje uzoraka i analiza scene, približno računanje (umjetne neuronske mreže,genetski algoritmi, neizrazita logika), te robotiku“ [5].

[4] Gold, H. (2003).Osnove inteligencije transportnih sustava. Dostupno na: https://vdocuments.site/osnove-inteligencije-transportnih-goldhitsits-00-osnove-inteligencijepdfosnove.html (24.02.2020)

[5] Gold, H. (2003).Osnove inteligencije transportnih sustava. Dostupno na: https://vdocuments.site/osnove-inteligencije-transportnih-goldhitsits-00-osnove-inteligencijepdfosnove.html (24.02.2020)

Slika 1. Razvoj i područja umjetne inteligencije



Izvor: Gold, H. (2003).Osnove inteligencije transportnih sustava. Dostupno na: https://vdocuments.site/osnove-inteligencije-transportnih-goldhitsits-00-osnove-inteligencijepdfosnove.html (24.02.2020)

Pavle Valerjev navodi sljedeće grane umjetne inteligencije[6]:

- Rješavanje problema je ogranak umjetne inteligencije koji uključuje razvoj algoritama.
- Predstavljanje znanja je ogranak umjetne inteligencije koji se bavi problemima predstavljanja i pohranjivanja korisnih informacija, izgradnje baze znanja i povezivanjem toga znanja s drugim znanjem na način koji će biti koristan.
- Automatsko rasuđivanje je ogranak umjetne inteligencije koji uključuje razvoj programa koji se temelje na logičkim zakonitostima.
- Planiranje i djelovanje je ogranak umjetne inteligencije koji važna u pristupu razumskih agenata.

[6] Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018.. str. 201

- Rasuđivanje u neodređenim uvjetima posebna je kategorija problema gdje se javljaju posebne poteškoće i kod predstavljanja neodređena znanja i kod odabira ispravnih algoritama za izvođenje optimalnih odluka.
- Učenje je nužna sposobnost svakoga sustava umjetne inteligencije, a algoritmi koji omogućuju određen tip učenja razlikuju se ovisno o sustavu.
- Procesiranje prirodnoga jezika, razumijevanje govora i automatski prevoditelji olakšavaju komunikaciju sa strojevima.
- Kompjutorski vid je ogranak umjetne inteligencije koji se bavi problemima vidne percepcije, što se manifestira prepoznavanjem i razlikovanjem objekata te njihovom usporedbom s objektima iz njegove memorije.
- Robotika je ogranak umjetne inteligencije koji u sebi uključuje navedene grane, a obvezno kompjutorski vid te planiranje i djelovanje

Pojam umjetne inteligencije je relativno širok i proteže se od svojstava koja se samo čine kao inteligentni do onih koji pokazuju inteligenciju koja se može izjednačiti s ljudskom inteligencijom. S obzirom na stupanj inteligencije, umjetna inteligencija se može podijeliti na jaku i slabu. Jaka umjetna inteligencija manifestira inteligenciju koja se može izjednačiti s ljudskom inteligencijom. Za prepoznavanje takva oblika inteligencije se kristi Turningov test po kojem je računalo inteligentno ako više od 30% osoba u komunikaciji s računalom nije u stanju prepoznati radi li se o stroju ili čovjeku. Slaba umjetna inteligencija jest ona kojoj se mogu pripisati tek neka inteligentna svojstva, npr. mogućnost prepoznavanja govora[7].

Jaka umjetna inteligencija naziva se i svjesnom umjetnom inteligencijom, a podrazumijeva stroj koji je sposoban ponašati se inteligentno, osjećati i razumijevati svoje rasuđivanje. Njome je moguće postići repliciranje ljudskih mentalnih svojstava kao što su emocije, kreativnost, motivacija i slično. Slaba umjetna inteligencija naziva se i ograničenom, a podrazumijeva gradnju više autonomnih sustava ili algoritama sposobnih rješavati problemska područja. Kod ove vrste umjetne inteligencije stroj nije inteligentan, već simulira inteligenciju. Kod slabe umjetne inteligencije strojevi mogu oponašati određena mentalna stanja, ali ih ne posjeduju[8].

- Sustavi umjetne inteligencije bazirani na neuronskim mrežama imaju sposobnost učenja. Učenje pomoću neuronskih mreža se odvija postupkom koji uključuje niz iteracija koje imaju za konačni cilj optimalno usklađivanje) vrijednosti težinskih faktora

[7] Prister, V. (2019). Umjetna inteligencija. Media, Culture and Public Relations, 10, 2019, 1, 67-72. str. 69
[8] Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018. str. 205

na osnovu pogreške između pomoću modela izračunate vrijednosti i realne vrijednosti mjerene veličine. Taj proces iterativnog učenja se obavlja po pravilima učenja koji se može odvijati po načelu „pravila širenja unatrag" ili „algoritma unatražne propagacije izlazne pogreške (engl. back propagation)". Prilikom svake iteracije se generira proračunata vrijednost koja se onda uspoređuje sa stvarnom vrijednosti, te se na osnovu utvrđenih razlika vrši postupak korekcije težinskih faktora čim se zapravo događa učenje na način da se te razlike između proračunate i realne vrijednosti smanjuju. U svrhu razvoja modela, eksperimentalni podatci se dijele u tri skupa[9]:

- skup za učenje- iterativnom korekcijom težinskih faktora se postiže minimiziranje pogreške na način ,
- skup za provjeru- u svakom koraku iteracije se generira nova vrijednost na skupu za provjeru, sve dok pogreška ne bude manja od specificiranog odstupanja ili se sama iteracije ne odvije do kraja
- skup za testiranje se koristi za konačnu provjeru. Ukoliko sposobnost predviđanja pomoću skupa za testiranje ne zadovoljava, onda se struktura modela može izmijeniti promjenom broja skrivenih neurona, promjenom broja prošlih vrijednosti ulaza i/ili izlaza ili promjenom aktivacijske funkcije.

Zaključno se može reći da su sustavi umjetne inteligencije oni sustavi koji mogu učiti nove koncepte, koji mogu zaključivati, razumjeti prirodni jezik, razumjeti različite vizualne prikaze, te obavljati i čitav spektar drugih aktivnosti koje zahtijevaju vještine imanentne čovjeku[10]

2.2. Primjena umjetnih neuronskih mreža unutar umjetne inteligencije

Umjetna inteligencija, kako je već ranije navedeno, nastoji imitirati ljudski mozak, odnosno nastoji na umjetan način imitirati inteligenciju kaj je imanentana ljudskom mozgu. Budući da se struktura ljudskog mozga sastoji od velikog broja živčanih stanica, odnosno neurona koji djeluju paralelno kad nastoje obrađivati najrazličitije vrsta informacija, tako to nastoji postići i područje računarstva koje se bavi tim aspektom obrade informacija, a koje se naziva neuro-

[9] Ujević Andrijić, Ž. (2019). Osvježimo znanje, Kem. Ind. 68 (5-6) (2019) 219–220. str. 220
[10] Gold, H. (2003).Osnove inteligencije transportnih sustava. Dostupno na: https://vdocuments.site/osnove-inteligencije-transportnih-goldhitsits-00-osnove-inteligencijepdfosnove.html (24.02.2020)

računarstvo, a koje se temelji na obradi podatka umjetnom neuronskom mrežom (engl. Artificial Neural Network, ANN). Ideja umjetnih neuronskih mreža se javila krajem prve polovice dvadesetog stoljeća, kada McCulloch i Pitts sa MIT-a, u nastojanju da kopiraju neurofiziološke karakteristike živih bića, objavljuju matematički model neuronske mreže u okviru teorije automata[11].

Neuronska mreža jest „skup međusobno povezanih jednostavnih procesnih elemenata, jedinica ili čvorova, čija se funkcionalnost temelji na biološkom neuronu, pri tome je obradbena moć mreže pohranjena u snazi veza između pojedinih neurona tj. težinama do kojih se dolazi postupkom prilagodbe odnosno učenjem iz skupa podataka za učenje". Neke karakteristike obrade podataka svojstveni neuronskim mrežama su da: „posjeduju sposobnost procjene nelinearnih odnosa uzoraka, posjeduju sposobnost prepoznavanja uzoraka u nejasnim ili manjkavim podacima koji dolaze iz različitih uređaja kao što su kamere i mikrofoni, robusne su na pogreške u podacima, posjeduju sposobnost uspostave vlastitih odnosa između podataka, posjeduju sposobnost rada s velikim brojem promjenjivih veličina ili konstanti, posjeduju sposobnost prilagodbe na okolini, moguća je jednostavna VLSI implementacija, te posjeduju sposobnost na temelju iskustva (primjera) kreirati znanje „[12]

U nastavku se navode primjeri uporabe umjetnih neuronskih mreža u različitim područjima[13]:

- Obrada jezika. Obrada jezika se odnosi na sustave za konverziju teksta u govor i konverziju govora u tekst što implicira sposobnost prepoznavanja govora i teksta, te na osnovu toga čak i prepoznaju govornika, ali i izražavanja pomoću govora i teksta ni slično.
- Prepoznavanje pisanih znakova. Ovdje je riječ o sposobnosti sustava da može iz slike, odnosno skeniranog dokumenta prepoznati pisani sadržaj. Danas se takvi procesi nazivaju servisi za optičko prepoznavanje znakova (eng, Optical character recognition, OCR)
- Kompresija slika. Kompresija slika se odnosi na sustave koji imaju sposobnost da u realnom vremenu obavljaju kompresiju i dekompresiju podataka.

---

[11] Dalbelo Bašić, B., Čupić, M., Jan Šnajder, J. (2008). Umjetne neuronske mreže. Zavod za elektorniku, mikroelektroniku i inteligentne sustave, Fakultet elektrotehnike i računarstva. Str. 4

[12] Dalbelo Bašić, B., Čupić, M., Jan Šnajder, J. (2008). Umjetne neuronske mreže. Zavod za elektorniku, mikroelektroniku i inteligentne sustave, Fakultet elektrotehnike i računarstva. Str. 9

[13] Ćupić, M. (2016). Umjetna inteligencija: Umjetne neuronske mreže. Zagreb: Fakultet elektrotehnike i računarstva. Str. 8

- Prepoznavanje uzoraka. Ovi sustavi posjeduju sposobnost prepoznavanja predmeta, pa svoju primjenu imaju u zračnim lukama koji skeniranjem prtljage prepoznaju potencijalno opasne, odnosno zabranjene predmete.
- Obrada signala. Ovi sustavi posjeduju sposobnost prepoznavanja signala i njihovih izvora, sposobnost korekcije signala, te filtriranja zvuka na način da uklanjaju šum iz signala
- Financije. U financijskom sektoru ovi sustavi trebaju nadomjestit čovjeka u poslovima koji se odnose na odlučivanje u području financija. Pritom se ovi sustavi osobito oslanjaju na učenje na temelju povijesnih podataka, čime se u mnogočemu ubrzava cijela proceduru odlučivanja.
- Upravljanje. Ovi sustavi se odnose na autonomno upravljanje različitim oblicima upravljanja prometnim sredstvima, kao što su automobili, zrakoplovi, brodovi isl., ali i autonomno upravljanje čitavim nizom strojeva i uređaja, kao što su kamere, laseri, roboti isl.

2.3. Primjeri upotrebe umjetne inteligencije u poslovanju

Postoji bezbroj stupnjeva na kojima tvrtke mogu primijeniti AI. Treba napomenuti da postoje sustavi sa slabom, srednjom i niskom uključenosti.[14] Slaba uključenost se sastoji od rješenja trećih strana koja ne zahtijevaju velike količine resursa (novac, vrijeme, stručnost itd.) za implementaciju i upravljanje. Nizak i srednji udio uključenosti AI je prisutan kod automatiziranih sustava koji smanjuju čovjekovo sudjelovanje u radnim i vremenski intenzivnim zadacima, ali zahtijevaju ručni nadzor i unos podataka. Aplikacije srednje uključenosti koriste umjereno robusne tehnologije u određenim područjima poslovanja. Ovi oblici AI nude usko usmjerene aplikacije koje karakterizira interaktivnost kupca s brendom. Implementacija AI visoke uključenosti obuhvaća najnapredniju tehnologiju. To su visoko prilagođeni interni AI sustavi izričito izgrađen za poduzeće koji se koristi tijekom odlučivanja i planiranja i provođenja i operacija.

U nastavku se iznose primjeri upotrebe umjetne inteligencije u nekim poslovnim aktivnostima.

[14] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University. Str. 22

1. Informacijske i sigurnosne tehnologije. Konzultantska tvrtka Gartner predviđa da će do 2020. godine najmanje **75%** digitalnih sigurnosnih alata uključivati prediktivnu i propisanu analizu koja se temelji na heuristikama (metoda za upravljanje znanjem), AI vještinama i algoritmima strojnog učenja[15].
2. Proizvodnja. Dobar primjer za upotrebu umjetne inteligencije u proizvodnji je automobilska industrija. Automobili postaju sve povezani i generiraju podatke koji se mogu koristiti na različite načine. Volvo koristi podatke kako bi predvidio kada će dijelovi otkazati ili kada će vozilima trebati održavanje. BMW je pak lider u tehnologiji bez vozača, a planira da automobili do 2021. nude Tier 5 autonomiju (vozilo koje može voziti bez ljudske intervencije). Revolucija AI tehnologije utjecala je i na poljoprivredu, gdje postoje rješenja korištenja naprednih algoritma strojnog učenja, kako bi roboti mogli donositi odluke na temelju vizualnih podataka, o tretiranju štetočina pesticidima. Svjetski lider u energetici, BP, koristi tehnologiju za postizanje poboljšanog korištenja resursa te sigurnost i pouzdanost proizvodnje i prerade nafte i plina. Od senzora koji prenose uvjete na svakom mjestu do korištenja tehnologije umjetne inteligencije za poboljšanje operacija[16].
3. Financije i računovodstvo. Konzultantska tvrtka Accenture predviđa da će se **80%** financijskih i računovodstvenih zadataka automatizirati u narednim godinama. KPMG je u suradnji s IBM-ovim pametnim računalom Watsonom, može pročitati tisuće stranica ugovora i sporazuma i sažeti ih gotovo odmah, na temelju postavljenih kriterija[17].
4. Ljudski resursi. Virtualni pomoćnik može se pobrinuti za zakazivanje sastanaka,preporučujući kontakte ili precizno pratiti zadaće zaposlenika na radnom mjestu[18].
5. Poslovno upravljanje. Primjene AI u poslovnom upravljanju uključuju[19]:

- filtre za neželjenu poštu
- pametnu kategorizacija e-pošte

[15] 7 ejemplos de aplicación de inteligencia artificial en el negocio. Dostupno na: https://mundocontact.com/7-ejemplos-aplicacion-inteligencia-artificial-negocio/ (01.04.2020)
[16] Contreras, A. (2020). Ejemplos de Uso de Inteligencia Artificial en los Negocios. Dsotupno na: https://tienda.digital/2019/01/04/ejemplos-de-uso-de-inteligencia-artificial-en-los-negocios/
[17] 7 ejemplos de aplicación de inteligencia artificial en el negocio. Dostupno na: https://mundocontact.com/7-ejemplos-aplicacion-inteligencia-artificial-negocio/ (01.04.2020)
[18] Casos de uso de Inteligencia Artificial en las empresas. Dostupno na: https://www.auraportal.com/es/casos-de-uso-de-inteligencia-artificial-en-las-empresas/ (01.04.2020)
[19] tificial intelligence in business. Dostupno na: https://www.nibusinessinfo.co.uk/content/examples-artificial-intelligence-use-business (01.04.2020)

- pretvorbe glasa u tekst
- pametni osobni asistenti, kao što su Siri, Cortana i Google Now
- automatizirana podrška kupcima
- automatizacija procesa
- predviđanje prodaje i poslovanja
- sigurnosni nadzor
- pametni uređaji koji se prilagođavaju prema ponašanju
- automatizirani uvidi, posebno za industrije utemeljene na podacima (npr. financijske usluge ili e-trgovina)

6. komunikacije. Unutar prepoznavanja prirodnog jezika ili NLP-a postoji ogranak posvećen procjeni emocionalnog stanja osobe na temelju pisanog ili pripovijedanog teksta20. Korištenje inteligentnih chatbotova za rješavanje incidenata s kupcima moglo bi biti jedno od najvažnijih poboljšanja u kratkom roku za poduzeća, zahvaljujući uštedama koje se mogu postići u podršci i službi za korisnike21. Gartnerova studija predviđa da će 25% radnika koristiti virtualne pomoćnike kao radni alat do 2021, dok će do 2023. zaposlenici komunicirati sa svojim radnim aplikacijama glasovnim naredbama[22].
7. Marketing i prodaja. Primjeri AI u marketingu uključuju[23]:

    - preporuke i izbor sadržaja
    - personalizacija vijesti
    - prepoznavanje uzorka i slike
    - prepoznavanje jezika - za pribavljanje nestrukturiranih podataka od kupaca i prodajnih izgleda
    - ciljanje oglašavanje segmentacija korisnika
    - socijalna semantika i analiza osjećaja
    - automatizirani web dizajn
    - prediktivna služba za korisnike

[20] Casos de uso de Inteligencia Artificial en las empresas. Dostupno na: https://www.auraportal.com/es/casos-de-uso-de-inteligencia-artificial-en-las-empresas/ (01.04.2020)
[21] Casos de uso de Inteligencia Artificial en las empresas. Dostupno na: https://www.auraportal.com/es/casos-de-uso-de-inteligencia-artificial-en-las-empresas/ (01.04.2020)
[22] Lazcano, R. (2020). Inteligencia artificial: ejemplos de cómo puede impactar a tu negocio inteligencia artificial. Dostupno na: https://blog.enzymeadvisinggroup.com/inteligencia-artificial-ejemplos (01.04.2020)
[23] Artificial intelligence in business. Dostupno na: https://www.nibusinessinfo.co.uk/content/examples-artificial-intelligence-use-business (01.04.2020)

3. MARKETING

3.1. Pojmovno određenje marketinga

Prema Ph. Kotleru, marketing je „društveni i upravljački proces u kojemu putem stvaranja ponude i razmjene proizvoda od vrijednosti s drugima, pojedinci i grupe dobivaju ono što im je potrebno ili što žele". Dakle, marketing kao disciplina nije dualan jer u temelju svoje koncepcije nastoji zadovoljiti obje strane- potrebe potrošača i potrebe poslovne [24]:

Prema Američkom udruženju za marketing „Marketing je aktivnost, skup institucija i procesi stvaranja, komuniciranje, dostavljanje i razmjena ponuda koje imaju vrijednost za kupce, klijente, partnere i društvo u cjelini. [25]"

Kritični aspekt marketinga je isporuka vrijednosti kupcima, dok vrijednost može predstavljati različite aspekte proizvoda kao što su roba, ideje, usluge, informacije ili bilo koja vrsta rješenja koja zadovoljavaju potrebe kupaca[26]

Razvoj marketinga je doveo do marketinškog koncepta koji je u potpunosti orijentiran na potrošače. Takav koncept uviđa da marketing nije samo prodaja, veća da je to proces koji treba biti prisutan u čitavom vijeku života proizvoda, od njegovog dizajna do proizvodnje, ali i cijelo vrijeme biti prisutan u svakoj etapi odnosa s potrošačem, od njegovog privlačenja do poslijekupovne suradnje. Ipak, iako mnogi poslovni subjekti prihvaćaju ovakve koncepcije marketinga koje su usmjerene prema potrošačima, u praksi dolazi do posvemašnjih problema u implementaciji iste. Da bi se nadišli ti problemi, razvijen je koncept tržišne orijentacije koji se opredmećuju kroz modele cjelovitog upravljanja kvalitetom (TQM - Total Quality Management) koji zahvaljujući svojoj sveobuhvatnosti omogućuju prisutnost orijentacije na potrošače kroz sve funkcije u poduzeću, od istraživanja i razvoja, proizvodnje, pa do prodaje i marketinga.. Prihvaćajući, koncept tržišne orijentacije, poduzeće svoje napore usmjerava na[27]:

a) stalno prikupljanje informacija o kupčevim potrebama i mogućnostima konkurenata;

---

[24] Zavišić, Ž. (2011). Osnove marketinga. Visoka poslovna škola Zagreb. Str. 1

[25] Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science. Str. 3

[26] Jarek, K., Mazurek, G. (2019). Marketing and Artificial Intelligence. Central European Business Review. Vol. 8 , No. 2. 46-55.str. 47

[27] Zavišić, Ž. (2011). Osnove marketinga. Visoka poslovna škola Zagreb. Str. 1

b) distribucija prikupljenih informacija kroz sve razine poduzeća;

c) upotreba informacija za stvaranje vrijednosti za kupce.

3.2. Marketinški koncepti i strateški pristupi u marketingu

U suvremenim uvjetima poslovanja, kao posljedica raznovrsnih isprepletenih društvenih čimbenika, se pojavljuje nova paradigma ponašanja poslovnih organizacija koja otvara brojne prilike i izazove za sve aktere na tržištu, kako za poslovne organizacije, tako i za kupce. Kada su u pitanju potrošači to se očituje kroz njihovu sve bolju informiranost, sve veću dostupnost proizvoda, pa time i veću mogućnost izbora, općenito snažniji položaj koji im omogućuju društvene mreže, zbog čega im u konačnici jača pregovaračka moć i zbog čega oni u postaju sve zahtjevniji. Sve se to neizostavno reflektira i na poduzeća na način da poduzeća moraju tome prilagoditi sve elemente proizvodnog miksa, ali i sve druge aspekte poslovanja kako bi zadovoljili sve zahtjevnije kupce i tako održali korak sa konkurencijom.[28].

Budući da su kupci danas zahtjevniji nego prije 20 godina, usluge kupcima postaju ključni dio marketinške strategije. Kupci žele izvrsnu uslugu, koja je empatična i kvalitetna. Zato je potrebno pratiti svaku razmjenu između poduzeća i kupaca. Kad je kupac zadovoljan pruženom uslugom, odnos postaje jači, što implicira da će također biti dugotrajan i za stolom

U takvi okolnostima segmentacija tržišta, pozicioniranje i potpuno integrirane strategije marketing miksa jesu glavne komponente uspješnog marketing u današnjem poslovanju. Potpuno integrirane i koherentne strategije marketinškog miksa čine najveći dio programa uspješnih marketinških strategija[29].

Kako bi poduzeća uspješno komunicirali sa svojim kupcima ona moraju prijeći s masovnog marketinga kojeg karakterizira odnos jedan prema mnogo na marketing odnosa koji karakterizira odnos jedan naprema jedan.

Danas u marketingu prisutna novi trendovi koji direktno ili indirektno pokazuju način na koji marketing prelazi iz koncepta masovnog marketinga na koncept marketinga koji je klijentocentričan, odnosno koji je usmjeren na kupce.Sve je to dodatno podržano informacijskom i telekomunikacijskom tehnologijom.[30]

---

[28] Gligorijević, M. (2009). Marketing odnosa na poslovnom tržištu Marketing : časopis za marketing teoriju. Vol. 40; Broj/Issue 4, QMJED 40 (3) 125- (2009). str. 213

[29] Akroush, M. (2010). Transactional marketing and relationship marketing paradigms: A structural equation modelling approach. International Journal of Electronic Customer Relationship Management. 4. str. 126

[30] Meler, Ma. (2005). Evolucija odnosa s potrošačima. Zagreb: Konferencija: XIX. Kongres CROMAR-a "Marketinške paradigme za 21. stoljeće"

Ta nova koncepcija koje je usmjerena prema kupcima zahtijeva i redefiniranje postojećih odnosa sa potrošačima. Naime, dosadašnji marketinški koncept marketinga je bio utemeljen na strategiji rasta, pri čemu je on bio usmjeren prema rastu prodaje i tržišnog udjela, a kupci su bili u drugom planu. Zapostavljane kupaca je posebno vidljivo ako bi se razmotrio različiti odnos poduzeća prema novim i starim kupcima, pri čemu poduzeća više energije i pažnje usmjeravaju na nove nego na postojeće potrošače. Međutim, nova paradigma ne samo da ne radi razliku između novih i starih potrošača, već ima konstantno na umu Paretovo načelo po kojem 20% potrošača donosi 80% prihoda,a također 20% potrošača donosi 80% problema, To jasno ukazuje kako privlačenje novih potrošača može koštati četiri do sedam puta više nego zadržavanje postojećih, pa to i jest jedan od razloga za promjenu u ponašanju poduzeća prema postojećim potrošačima.

Međutim, treba napomenuti da ovakav nov koncept i nije u potpunosti nov, već je on nadogradnja nekih već zaboravljenih marketinških pristupa. Naime, u doba manufakturne proizvodnje se je odvijalo slično poslovanja, pa je tako primjerice krojač za svakog kupca šivao posebno odijelo po mjeri. Kasnijom modernijom i masovnijom proizvodnjom ta se ista odjela kroje prema određenim veličinama, a ne više po mjeri svakog kupca ponaosob, već su kupci tražili sebi najoptimalniju veličinu od ponuđenih. Sadašnji trendovi ukazuju na to da će u budućnosti biti opet moguća totalna segmentacija (eng. mass customization) Naime, razvoj informatičke tehnologije, posebno interneta, je već danas omogućio kupcima da putem interneta mogu naručivati odjeću po točno specificiranim dimenzijama, uzorcima, materijalima, krojevima isl, pri čemu poduzeća opet mogu u kratkom vremenu sašiti ta odjela po po mjeri svakog kupca, iz čega proizlazi da će se pet biti moguće u velikom broju djelatnosti vratiti na proizvodnju po narudžbi. Na taj način se opet govori o uspostavi marketinga koji je prezentiran odnosom jedan na jedan gdje god je to moguće i izvedivo. Ovakvim klijentocentričnim pristupom, usmjerenom pojedinačnom potrošaču se želi prepoznati pojedinačne potrošače proizvoda, za razliku od marketinga utemeljenom na masovnoj prilagodbi (mass customization) koji tendira prilagoditi proizvode i samu proizvodnju specifičnim potrebama tako identificiranim potrošačima[31].

[31] Meler, Ma. (2005). Evolucija odnosa s potrošačima. Zagreb: Konferencija: XIX. Kongres CROMAR-a "Marketinške paradigme za 21. stoljeće"

U tablici 1. su iznesene osnovna gledišta transakcijskog marketinga i marketinga odnosa.

Tablica 1. Strateška gledišta transakcijskog marketinga i marketing odnosa

Strateški aspekti	Transakcijski marketing	Relationship marketing
Vremenska perspektiva	Kratki životni vijek transakcije	Dugačak životni vijek odnosa
Dominirajuća funkcija marketinga	Marketinški splet	Interaktivni marketing)
Elastičnost cijene	Veća cjenovna elastičnost	Manja osjetljivost na cijenu
Dominirajuća dimenzija kvalitete	Kvaliteta outputa (tehnička dimenzija)	Kvaliteta interakcija/odnosa (funkcionalna dimenzija)
Mjerenje	Orijentirano na mjerenje tržišnog udjela	Orijentirano na mjerenje kupaca
Međuovisnost marketinga i ostalih funkcija zaposlenika	Izostanak strategije	Strateški važno
Uloga internog marketinga	Nije relevantno za uspjeh	Strateški važno

Izvor: Dukić, B., Gale, V. (2015). Upravljanje odnosima s potrošačima u funkciji zadržavanja potrošača. Ekonomski vjesnik : Review of Contemporary Entrepreneurship, Business, and Economic Issues, Vol. 28 No. 2, 2015.

Nastavno na navedenu razlike između masovne prilagodbe i marketinškog pristupa jedan na jedan, ovdje treba napomenuti da u marketingu postoji podjela na koncepcije i transakcijskih teorija koje namjeravaju obaviti jednu transakciju i strategija marketinga odnosa koje su oblikovane da kreiraju dugoročne odnose s kupcima. Pri tome treba navesti da postoje tri kategorije relacijskog marketinga: „marketing zasnovan na bazi podataka, interakcijski marketing i mrežni marketing“ [32].

Dakle, transakcijski se marketing svodi na jednu ili više transakcija bez namjere da se uspostavi trajniji odnos sa kupcima, već sa namjerom da se proda, pa se ta strategija može opisati kao „Run and Gun“ strategija. Takve transakcijske strategije ne zahtijevaju zahtijevaju uzajamno priznavanje i poznavanje između strana. U marketingu utemeljenom na bazi podataka se ide ipak korak dalje, te se transakcija nadograđuje razmjenom informacija pri čemu se nastoji uspostaviti komunikacija kroz neko vrijeme, pa to znači i svojevrsnu uspostavu odnosa. Pri

[32] Meler, M. (2005). Evolucija odnosa s potrošačima. Zagreb: Konferencija: XIX. Kongres CROMAR-a "Marketinške paradigme za 21. stoljeće"

tome se koristi informacijska i telekomunikacijska tehnologija za bilježenje podataka u baze podataka o postojećim i potencijalnim kupcima, kako bi im se mogao isporučiti diferencirani proizvodi na temelju njihovih osobnih osobina i preferencija. Interakcijski marketing se odvija kroz neposrednu interakciju licem u lice između kupaca i poslovnih subjekata. Mrežni marketing se odvija na način da poslovni subjekti koriste svoje resurse kako bi uspostavili i poboljšali odnose u mreži odnosa sa svim zainteresirani stranama [33].

3.3. Trendovi u digitalnom marketingu

Elektronički marketing (ili skraćenica e-marketing) definira se kao „proces kreiranja ponude, određivanje cijena, distribucije i promocije s ciljem profitabilnog zadovoljavanja potreba i želja kupaca uz intenzivno korištenje mogućnosti digitalne tehnologije". Drugačije rečeno, upotrebom digitalnih tehnologija se realiziraju ciljevi marketinga..[34]

Prema Institutu izravnog marketinga, digitalni marketing „uključuje korištenje digitalne tehnologije koja kreira nove marketinške kanale s ciljem potpore marketinških aktivnosti usmjerenih na profitabilno osvajanje i zadržavanje kupaca u multikanalskom procesu kupnje". Dakle, digitalni marketing će polučiti najbolje rezultate u sinergiji s drugim kanalima..[35]

Najčešće su tehnike e-Marketinga sljedeće[36]:

- Affiliate marketing
- Permission marketing
- Referral marketing
- Content marketing
- E-mail marketing
- Real-time marketing

Viralni marketing je „poslovna strategija koja koristi postojeće društvene mreže za promociju proizvoda. Viralni marketing se odnosi na to kako potrošači šire informacije o proizvodu s drugim ljudima na svojim društvenim mrežama, gotovo na isti način na koji se virus širi od jedne osobe do druge". Osnova virusnog marketinga je u širenju informacija usmenim

[33] Meler, M. (2005). Evolucija odnosa s potrošačima. Zagreb: Konferencija: XIX. Kongres CROMAR-a "Marketinške paradigme za 21. stoljeće"
[34] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 82
[35] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 82
[36] VUP. Tehnike E- marketinga, dostupno na: https://www.vup.hr/_data/files/13052711478326.pdf (01.03.2020)

putem od usta do usta ali suvremena tehnologija omogućila je da virusni učinak uključi i mnoge platforme utemeljene na Internetu.[37]

Affiliate marketing je „model oglašavanja u kojem poduzeće angažira treću stranu da generira promet ili dovedu do proizvoda i usluga poduzeća. Treća strana su podružnice, a provizija za poticanje potiče ih da pronađu načine za promociju poduzeća. Internet je povećao važnost affiliate marketinga, posebice kad je Amazon popularizirao praksu izrade partnerskog marketinškog programa u kojem web stranice i blogeri stavljaju linkove na stranicu Amazona kad bu u nekom kontekstu spominjali proizvod (npr. popis dijelova ili sastojaka za neki proizvod) uz naknadu za oglašavanje"[38]

Permission marketing (marketing uz dozvolu) predstavlja pristup prodaji robe i usluga u kojem potencijalni klijent izrijekom unaprijed prihvati primanje marketinških informacija. E-mail za prijavu, gdje se korisnici interneta unaprijed prijave za informacije o određenim kategorijama proizvoda, dobar su primjer marketinga dozvola. Zagovornici marketinga dozvola navode da je riječ o učinkovitoj strategiji jer potencijalni klijent bolje prihvaćaju poruku koja je unaprijed zatražena i ekonomičnija, jer je klijent već identificiran i ciljan[39].

Referral marketing je „tehnika za promociju proizvoda ili usluga novim klijentima putem preporuka, obično usmeno. Takve se preporuke redovito događaju spontano, ali organizacije mogu to utjecati primjenom odgovarajućih metodologija"[40]. Referral marketing se u praksi vrlo često provodi kao koncept reci prijatelju, pri čemu se partneri nagrađuju dovođenjem novog člana u organizaciju.[41]

- Content marketing (marketing sadržaja) ili Inbound Marketing „objedinjuje marketinške strategije i aktivnosti u svezi s objavljivanjem i distribucijom sadržaja, s ciljem angažiranja postojećih i potencijalnih klijenata".[42]

---

[37] Viral marketing. Dostupno na: https://www.marketing-schools.org/types-of-marketing/viral-marketing.html (01.04.2020)
[38] Frankenfield, J. (2019). Affiliate Marketing. Dostupno na: https://www.investopedia.com/terms/a/affiliate-marketing.asp
[39] Permission Marketing. Dostupno na: https://searchcustomerexperience.techtarget.com/definition/Permission-Marketing (01.04.2020)
[40] Referal marketing. Dostupno na: https://studiousguy.com/referral-marketing-definition-strategies/ (01.04.2020)
[41] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 196
[42] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 196

- E-mail marketing je „oblik direktnog marketinga koji koristi elektroničku poštu kao sredstvo komuniciranja, odnosno dostavljanja komercijalnih poruka publici“[43].
- Real-time marketing podrazumijeva „prepoznavanje pravog trenutka i njegovo pametno korištenje za vlastitu promociju“[44]

Chaffey i Smith objašnjavaju temeljne cjeline prednosti elektroničkog marketinga sa svojim 5S modelom u kojem izoliraju 5 široko definiranih prednosti, razloga ili ciljeva e-marketinga:[45]

- Sell - povećavanje prodaje (kroz širu distribuciju, promociju i prodaju),
- Serve - dodavanje vrijednosti (ostvarivanje dodatne vrijednosti za kupce u digitalnom okruženju),
- Speak - približavanje kupcima (kroz analizu „digitalnog auditorija“, stvaranje dijaloga i učenjem o svojim kupcima),
- Save - smanjivanje troškova (ušteda na troškovima usluga, promocije, prodajnih transakcija, administracije, tiska i slanja),
- Sizzle – osnaživanje vrijednosti marke i lojalnosti prema marki u digitalnom okruženju.

[43] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 196
[44] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 196
[45] Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku. Str. 117

4. UMJETNA INTELIGENCIJA U MARKETINGU

4.1. Uloga umjetne inteligencije u privlačenju, uvjeravanju i zadržavanju kupaca

Tehnologija dubokog učenja može se koristiti za AI alate poput profiliranja, prilagodbe, automatizacije i proširenja zadataka. Alati se temelje na informacijama i rezultatima analize velike količine podataka i nude nove mogućnosti interakcije između kupaca i trgovaca. Primjer za to je alat "IBM Watson Customer Experience Analytics". Ovaj program se može povezati s web stranicom poduzeća gdje analizira sve podatke. Obavlja analizu ponašanja posjetitelja i identificira obrasce ponašanja. Na temelju toga je trgovcima omogućeno bolje razumijevanje interakcije svojih korisnika s web stranicom, na osnovu čega je moguće prepoznati prepreke i poboljšati zadovoljstvo[46].

Otkrivanjem obrazaca u podacima, AI mogu predložiti najbolje preporuke za zadovoljenje potreba potrošača učinkovitije nego što to mogu ljudi[47].

Kupci koji se profiliraju mogu se razvrstati u dva područja: promociju i CRM. Profiliranje znači opisati kupce na temelju njihovih atributa kako bi se identificirale i opisale karakteristike grupe ljudi. Analiza velikih podataka pomaže trgovcima da bolje razumiju kupce i omogućava im da ih bolje ciljaju i prilagodite marketinške poruke. Prije profiliranja prethodi korak segmentacije tržišta i korisnika. Segmentacija tržišta skenira korisnike po sličnosti i razvrstava ih u homogene skupine.

Segmentacija tržišta, koja se naziva i profiliranje kupaca, je marketinška strategija koja uključuje podjelu širokog tržište na podskupove potrošača, poduzeća ili zemalja koje imaju ili se smatraju da imaju zajedničke karakteristike, potrebe, interese i prioritete, a zatim dizajniranje i provođenje strategija za njihovo ciljanje.[48]

Segmentacija korisnika detaljno i pregledava svakog kupca pojedinačno i analizira njihovo ponašanje (učestalost, i novčanu vrijednost) i njihove vrijednosti. Postoje različiti načini profiliranja. Demografsko profiliranje, gdje se analiza temelji na demografskim kategorijama

[46] Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science, str. 2

[47] Kietzmann, J., Paschen, J., Treen, E. (2018). Artificial Intelligence in Advertising: How Marketers Can Leverage Artificial Intelligence Along the Consumer Journey. Journal of Advertising Research 58(3):263-267. str. 264

[48] Sterne, J. (2017). Artificial Intelligence for Marketing: Practical Applications. Wiley and SAS Business Serie. Str. 131

poput spola, starosti, prihoda, obrazovanja itd. Drugi oblik profiliranja je bihevioralno profiliranje. Ovaj se pristup više usredotočuje na stav, upotrebu i povratni informaciju kupaca prilikom susreta s proizvodom.[49]

U zagovaranju statističkih metoda za segmentaciju tržišta, ističe se da strojevi posao obavljaju brže, jeftinije i bolje. Na primjer, strojno učenje može prepoznati kako ponašanje regije ili zemlje varira od globalne norme i zahtijeva određeni asortiman proizvoda i cjenovni miks ili npr, vremenske varijacije mogu pokazati da kasnonoćni kupci imaju veću sklonost napuštanju košarice.[50]

Glavna prednost usvajanja AI-a u marketingu je da je putem AI poduzeće u mogućnosti pružiti poboljšanu uslugu i isporučiti veću vrijednost kupcima tako što ih dovode do maksimalne razine zadovoljstva. Ostale pogodnosti uključuju analizu velike količine podataka i učinkovito rukovanje marketinškim procesima[51].

Mogućnost AI-a za personaliziranje korisničkih iskustava može se primijeniti na korisnika kroz dizajn sučelja (UI) i korisničko iskustvu (UX). Integrirajući AI u načinu interakcije kupaca s mrežnim robnim markama tvrtke mogu biti u mogućnosti optimizirati svoje web stranice u stvarnom vremenu i prilagoditi ih pojedinačnom ponašanju potrošača. Takve personalizirane aplikacije imaju ogroman potencijal[52]

Upravljanje odnosima s kupcima (CRM) vrlo je važan aspekt u marketingu. Kao i mnogi poslovni procesi, može biti optimiziran uz pomoć AI alata. Odličan primjer za to je proces upravljanja i zakazivanja aktivnosti prodajnog osoblja. Na temelju rezultata rudarenja podataka i profiliranja, alati za duboko učenje mogu optimizirat i zakazivati i raspoređivati zadatke osoblja za pružanje bolje usluge kupcima. Također, primjenom kognitivnog računanja se mogu automatizirati zadatci koji se učestalo ponavljaju čime se štedi vrijeme i povećava produktivnost.[53]

---

[49] Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science, str. 3

[50] Sterne, J. (2017). Artificial Intelligence for Marketing: Practical Applications. Wiley and SAS Business Serie. Str. 131

[51] Zafeer Shahid, M., Li,G. (2019). Impact of Artificial Intelligence in Marketing: A Perspective of Marketing Professionals of Pakistan. Global Journal of Management and Business Research: EMarketingVolume 19 Issue 2 Version 1.0 Year 2019. str. 31

[52] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University str. 68

[53] Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science, str. 3

Iz gore navedenog je vidljivo da su čimbenici koji utječu na integraciju AI: tržišni pritisak konkurencije, medijska pažnja, digitalna zrelost i kupci. AI u marketing odgovara na te izazove osiguravajući poboljšanu analizu podataka i učinkovito rukovanje marketinškim procesima. Bolje razumijevanje podataka o kupcima povećava učinkovitost, smanjuje troškove, omogućuju bolje stope pretvorbe, povećava ROI, te u konačnici uvodi poboljšane usluge i povećava zadovoljstvo korisnika[54].

Poduzeća mogu pratiti ponašanje svojih kupaca na mreži i mogu iskoristiti sve podatke koje kupci ostave za sobom. Nadalje, prikupljeni podaci se koriste za prilagođavanje funkcije preporuke i prilagodbe sučelja za personaliziranu uslugu. Poduzeća poput Amazona su otišle još jedan korak dalje stvaranjem pametnog virtualnog pomoćnika koji asistent nudi pomoć u aktivnostima poput pretraživanja informacija, obavljanja digitalnih zadataka ili kupnje predmeta na mreži.[55]

Poseban način kojim marke mogu putem AI-a komunicirati sa svojim kupcima na osobnoj razini je tehnologija prepoznavanja lica. Marke AI Marketing Era mogu prikazivati vrlo personalizirana iskustva sa svojim kupce u stvarnom vremenu kako bi ih oduševili i stvorili dugotrajne veze. Osim toga, moguće je koristiti i novu kategoriju marketinških mjernih podataka u vidu sposobnosti računala da čita i razumije izraze lica kupaca na osnovu čega je moguće inteligentno analizirati osjećaje koje izražavaju kupci, te ih pretvoriti u količinski mjerljive podatke koje trgovci mogu upotrijebiti za određivanje točaka u kojima se događaju ključne promjene raspoloženja. Te informacija bi se mogli zatim koristi za usmjeravanje bezbrojnih marketinških napora poput personalizacije, poboljšanje kvalitete korisničkog sučelja u kritičnim točkama ili optimiziranje kampanja za razine emocija.[56]

„Influencer marketing" postao je svojstven specijalitet. Pronaći one koji imaju utjecajnu moć i natjerati ih da kažu nešto lijepo o marki. Ovo je klasični odnos s javnošću u doba Twittera. Identificirajući željene rezultate, stroj će pronaći utjecajne pojedince kao onaj čije ideje cvjetaju i šire se. Pritom računalo uzima u obzir[57]:

---

[54] Zafeer Shahid, M., Li,G. (2019). Impact of Artificial Intelligence in Marketing: A Perspective of Marketing Professionals of Pakistan. Global Journal of Management and Business Research: EMarketingVolume 19 Issue 2 Version 1.0 Year 2019. str. 32

[55] Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science, str. 3

[56] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University. Str. 50

[57] Sterne, J. (2017). Artificial Intelligence for Marketing: Practical Applications. Wiley and SAS Business Serie. Str. 131

- Je li influencer spomenuo vašu najnoviju promociju marke?
- Je li influencer povezao video marke?
- Je li influencer ponovno objavio fotografiju marke?
- Je li influencer spomenuo marku?
- Jesu li drugi slijedili utjecaj influencera i poduzeli mjere?
- Je li neki od gore navedenih utjecao na ključne indikatore

Kada je u pitanju AI u marketingu, ključna je tema istraživanje. AI nudi poboljšanje postojeće marketinške taktike za upoznavanje kupaca. Na primjer, programsko oglašavanje i medijski marketing može omogućiti cjelovitiji prikaz ponašanja kupaca, prediktivnu analitiku i dublje uvide kroz integraciju s AI. Novi marketinški alati poput biometrije, te glasovna i razgovorna korisnička sučelja nude nove načine stvaranja vrijednosti za marke i potrošače. Sve ove inovacije imaju slične karakteristike hiper-personalizacije, skalabilna iskustva i duboki uvid u kupce.[58]

Tablica 2. Primjeri primjene AI u marketingu

AI područja	**Primjeri primjene u marketingu**
Obrada glasa	Izdavanje glasovnih narudžbi za kupnju • Virtualni pomoćnici koji podržavaju izvršenje zadatka (Siri, Google početna, Cortana)
Obrada teksta	Korištenje virtualnog pomoćnika kao vodiča koji kupca vodi kroz kupovinu središte (Alpine.AI). • Razvoj i pokretanje novih i modifikacija postojećih proizvoda zahvaljujući informacijama koje je prikupio chatbot
prepoznavanje i obrada slika	• Prepoznavanje lica u procesu plaćanja i identifikacije kupca • pretraživanje interneta pomoću fotografija •Upotreba klijentove slike lica za pojedinačnu odabir nekih vrsta proizvoda kao što je kozmetika • analiza potreba pomoću analize putem video kamere u graditeljstvu

[58] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University. Str. 2

	• elektronička ogledala u trgovini odjećom (FashionAI).
Odlučivanje	• odabir turističkih destinacija na temelju sklonosti. • Chatbot koji priprema recept koristeći sastojke koje potrošač ima kod kuće i na temelju potrošačevih preferencija. • Dinamično prilagođavanje cijena korisniku na temelju prijašnjih kupovina • Usklađivanje oglasa s karakteristikama korisnika na temelju nečije internetske povijesti • Nove preporuke proizvoda • Otkrivanje kvarova i pogrešaka u funkcioniranju i proizvoda, te sinkronizacija popravka od strane tehničkog tima odgovornog za nadgledanje i popravak uređaja • Sinkronizacija podataka o kupcima sa svih mogućih kontaktnih točaka s markom (društveni mediji, web stranica, e-pošta, telefonski razgovor).
Autonomni roboti i vozila	• Trgovine bez osoblja • Robot za provjeru zaliha na policama trgovina i rasporeda proizvoda, te slanje podataka o nedostacima uslužnom osoblju

Izvor: Jarek, K., Mazurek, G. (2019). Marketing and Artificial Intelligence. Central European Business Review. Vol. 8 , No. 2. 46-55.. str. 49

Na koncu se mogu klasificirati glavne značajke Ai u marketingu kako slijedi[59]:

- Hyper-personalizacija AI omogućava da se marke povežu i oduševe svoje kupce na individualiziranoj razini. Pomoću praćenja i analiziranja izvora podataka, trgovci mogu postići sveobuhvatne prikaze svojih kupaca kako bi potaknuli njihove marketinške napore. To omogućuje robnim markama da pruže visoko personalizirane višenamjenske marketinške aktivnosti. Hiper-personalizacija pomoću AI olakšava razinu intimnosti između marki i potrošača kako to prije nije bilo moguće.
- Učinkovita potrošnja Kombinacija automatiziranja vremenski intenzivnih zadataka, sveobuhvatno razumijevanje ciljane publike i duboki uvid u marketinške performanse

[59] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University. Str. 26

dovodi do toga da trgovci mogu smanjiti troškove u mnogim svojim aktivnostima jer više ne trebaju trošiti marketinška sredstva na kupce koji ne doprinose njihovim ciljevima. Osim toga, to omogućuje smanjenje vremena zaposlenika potrošen na ponavljajuće zadatke, te im omogućava veći fokus na aktivnostima koje donose dodatnu vrijednost..

- Dublji uvidi AI nude robnim markama bolju vidljivosti kod kupaca. Naime, segmentacija korisnika može učinkovitije ostvariti duboki uvidom u ponašanje potrošača na makro i mikro razinama, a kampanje se mogu brže i bolje pratiti i analizirati, te na osnovu toga donositi kvalitetnije marketinške strateške odluke. Budući da poduzeća mogu iskoristiti te podatke za sveobuhvatno razumijevanje njihovih kupaca, to kupcima potrošače osigurava veću relevantnost marketinških poruka koje dobivaju uz visoku kontekstualizaciju i personalizirano iskustvo.
- Pristupačnost AI omogućava robnim markama da automatiziraju mnoge korisničke aktivnosti koje su ranije zahtijevale ljudski rad. Brandovi mogu ostvariti niže troškove prilikom zapošljavanja, obuke i upravljanje zaposlenicima, istodobno omogućavajući kupcima pristup tvrtkama kanalima samoposluživanja (kao što su chatbotovi, , osobni asistenti isl.).
- Skalabilna iskustva Poduzeća i kupci će imat na raspolaganju arsenal alata koji će na na vrlo personalizirani način komunicirati jedan na jedan. Vrlo interaktivna iskustva pomoću AI (poput biometrije, prepoznavanja lica, analize emocija itd.) omogućuju bolje interakcije između marki i potrošača. zahvaljujući individualiziranom marketingu, kupci mogu uživati u sadržaju prilagođenim njihovim interesima, težnjama i potrebama.

4.2. Alati za primjenu umjetne inteligencije u marketingu

Tržišta u cijelom svijetu rade na optimizaciji marketinških operacija i učinkovitosti koristeći obilje podataka. Mnogi se okreću alatima i platformama koje pokreću umjetna inteligencija i strojno učenje. Područja fokusa uključuju automatizaciju i optimizaciju oglašavanja, chat botove za uslugu i pomoć u prodaji te personalizaciju sadržaja U nastavku ovog rad će se prikazati neki od tih alata.[60]

[60] Odden, L. 54 Artificial Intelligence Powered Marketing Tools. Dostupno na: https://www.toprankblog.com/2018/03/artificial-intelligence-marketing-tools/ (01.03.2020)

AI marketinški alati mogu se podijeliti u sljedeće kategorije[61]:

1. Alati za personalizaciju- Personalizacija je jedna od najvažnijih kategorija, posebno za mrežni marketing. AI marketinški alati mogu vam pomoći u personaliziranju sadržaja. Takve AI tehnologije generiraju web stranice, e-poštu, postove na društvenim medijima i videozapise, personalizirane i jedinstvene za svakog korisnika.

Učinkovitost marketinške strategije danas ovisi o razini personalizacije. Što je kampanja personaliziranija, to više klijenata može privući. Takvi AI marketinški alati mogu pomoći trgovcima da konkretnije ciljaju svoju publiku pomoću personaliziranog sadržaja. Nadalje, lako se može odrediti u kojoj su fazi konverzije njihovi kupci. Primjer takvih alata su: Optimizely, Dynamicyield, Personyze, Qubit., Liftigniter i Onespot.

2. Alati za E-poštu- Uz umjetnu inteligenciju, generiranje sadržaja e-pošte, kao i vrijeme i učestalost e-mail kampanje mogu se optimizirati na temelju ponašanja svakog kupca. Primjer takvih alata su: Sendx, Drip, Mailchimp, Converkit i Emarsys.

3. Chatbotovi- Većina postojećih chatbotova već je integrirana na mnogim web mjestima i korisnicima pružaju korisničku podršku kroz chat usluge. Jednostavniji rade na temelju klasičnih pravila / skripti, ali napredniji chatboti implementiraju i algoritme strojnog učenja. U skladu s tim, botovi umjetne inteligencije mogu se prilagoditi različitim kupčevim ponašanjima. Primjer takvih alata su: Botsify. Flowxo, Imperson, Manychat i Itsalive.

4. Alati za prediktivnu analitiku- Danas su u mrežnom marketingu potrebni redovit nadzor i analiza kampanja. Pomoću AI marketinških alata se lako može dobiti statistika i izvješća s raznih kanala na jednom mjestu. Ova vrsta marketinških alata primjenjuje AI metode poput prediktivne analitike. Primjer takvih alata su:Mintigo i Nexoya.

5. Alati za segmentaciju korisnika- Povijesni podaci o ponašanju za svakog kupca mogu pružiti mogućnost boljeg segmentiranja kupaca. Metode segmentacije omogućuju stvaranje prilagođenih ponuda, bolje korisničko iskustvo i pojedinačno prilagođene promocije. Neki od sljedećih marketinških alata već koriste AI u svojim tvrtkama ili ga uskoro planiraju primijeniti: Amplituda, Appier, Affinio, Optimove 6, Articoolo, Curata, Wordsmith, Articleforge

7. Alati za automatizaciju kampanje- Na tržištu je dostupan veliki broj alata za automatizaciju marketinške kampanje. Ovi AI marketinški alati trgovcima nude automatizaciju upravljanja

[61] Nexoya. AI marketing tools that you need to know. Dostupno na: https://www.nexoya.com/blog/ai-marketing-tools-that-you-need-to-know/ (01.03.2020)

kampanjama na svim kanalima. Primjeri takvih alata su: Socialpilot, Agilecrm, Activecampaign i Smartly

4.3. Uloga i pozicija ljudi u primjeni umjetne inteligencije u marketingu

Budući da je marketing polje koje zahtijeva analitičko i kreativno razmišljanje, samo po sebi je jasno je da se u marketinškom procesu posebna pažnja treba posvetiti upravo analizi i kreativnosti. U tu svrhu alati umjetne inteligencije pružaju nezamjenjivu pomoć. Zaposlenici, zahvaljujući tome što su oslobođeni obavljanja mnogih rutiniranih poslova koje su preuzeli alati umjetne inteligencije, imaju više vremena za zadatke vezane uz kritičko mišljenje i kreativnosti. Kao rezultat toga, poduzeća mogu očekivati povećanje fokusiranosti na kreativnost u njihovom svakodnevnom radu jer je za to predviđeno više vremena. Zahvaljujući tome će mekani skupovi vještina kao što su kreativnost i empatija sve više služiti izvorima konkurentne diferencijacije. Takve organizacije sve više postaju lideri na tržištu. AI utječe na kreativnost u marketingu [62]:

1.) pružajući dublje uvide kako poboljšati kreativnost i kako oblikovati kreativnu strategiju

2.) omogućavaju kreativnosti da postane presudna diferencirajući faktor za tvrtke omogućavanjem smislenog, utjecajnog i personaliziranog iskustva,

3.) optimiziraju učinkovitosti kreativnih sredstava tako što ih isporučuju kupcima na pravi način u pravo vrijeme i

4.) automatiziraju ponavljajuće i rutinske zadatke i tako oslobađaju vrijeme za kreativan rad.

AI pomaže trgovcima u automatizaciji obogaćivanja marketinške imovine (tj. sadržaja, slika, video zapisa) kako bi mogli bolje iskoristiti svoje resurse i rješenja za upravljanje digitalnom imovinom (DAM). Ova tehnologija također može obavljati neke zadatke s obilježjima kritičkog razmišljanja, kao što su pretvorba govora u tekst i obrnuto, prepoznavanje lica i gestikulacija, analiza osjećaja i na osnovu toga može pružiti preporuke za upotrebu digitalne imovine. Kroz

[62] Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University. Str. 52

automatizaciju ovih bitnih, ali dugotrajnih procesa, trgovci će imati prednost snažnijeg DAM rješenja uz[63]:

- Poboljšana ponovna upotreba sadržaja
- Skraćeno vrijeme pretraživanja sadržaja
- Smanjeni troškovi stvaranja sadržaja
- Isporuka bogatijih iskustava
- Povećalo zadovoljstvo korisnika

AI omogućava trgovcima da pređu od jednostavnog "poznavanja" do istinskog "razumijevanja" svojih kupaca. Demografski, zemljopisni podaci mogu samo pružiti osnovno razumijevanje kupca. Međutim, samo detaljna analiza ponašanja na izvanmrežnim i mrežnim kanalima na više uređaja može stvoriti jedinstven pogled na kupca na 360 stupnjeva. Što više trgovci sveobuhvatnije razumiju svoje ciljne kupce, njihove simpatije i sklonosti, to je lakše, individualizirati digitalne marketinške kampanje. Tijekom određenog vremena, AI može omogućiti trgovcima da zahvaljujući inteligentnoj segmentaciji steknu osjećaj predvidljivosti u ponašanju pojedinog kupca.

Uloga ljudi u oglašavanju se ne smanjuje, već se značajno mijenja. To najbolje opisuje fraza koju koristi Google: "Pametni ljudi s pametnim strojevima." Cilj ovih AI implementacija nije zamjena ljudi već pružanje alata za postizanje boljih rezultata. Čovjek koji pravilno koristi AI ostvarit će bolje rezultate nego što je to mogao sam postići. Ljudi koji žele izvući maksimum iz svojih marketinških napora moraju preusmjeriti svoju perspektivu da se usredotoče na svoje snage i omoguće strojevima da rade ono što najbolje rade. Baš kao što je industrijska revolucija dopustila ljudima da prekorače svoja fizička ograničenja, tako će AI omogućiti da ljudi prijeđu granice spoznaje. Ljudi nikada neće nadmašiti AI kada je u pitanju testiranje i optimizacija podataka, ali strojevi nikada neće razumjeti ljude. Uloga ljudi u suvremenom marketingu je temeljito razumijevanje drugih ljudi i pružanje boljih podataka umjetnoj inteligenciji za daljnje testiranje i optimizaciju[64]

Prilikom bavljenja ovom problematikom nužno se nameće pitanje dominacija strojeva nad ljudima. Veliki broj istraživača upozorava kako razvojem ove tehnologije čovjek ide prema svomu samouništenju. Tako J. Bryson i J. Wyatt u djelu Artificial Intelligence naglašavaju kako će računala postati toliko moćna da se u budućnosti može očekivati da će stoj uništiti čovjeka.

[63] Breault, E. (2019). 4 Ways AI Is Transforming Marketers' Roles. Dostupno na: v (02.03.2020)
[64] Baker, R. (2020). Opinion: Modern marketing: AI vs. humans. dostupno na: https://sbj.net/stories/opinion-modern-marketing-ai-vs-humans,67788? (01.03.2020)

Nick Bostrom je da bi u slučaju da čovjek uspije napraviti umjetni mozak koji je superiorniji ljudskom mozgu čovjek bi mogao postati ovisan o takvoj superinteligenciji. Naglasio je kako uopće nije upitno da se čovječanstvo nalazi na pragu velikoga prodora u umjetnoj inteligenciji. Douglas R. Groothuis upozorava na opasnosti kojom živo postaje podložno neživu. Pozitivnim vidi promicanje raznovrsnih oblika komunikacija među ljudima, ali upozorava na ono što se može dogoditi kod poremećaja u radu računalnoga programa. Zahvaljujući psiho-ontološkoj datosti koju nosi u sebi, čovjek je jedinstven i nijedan ga stroj u potpunosti ne može oponašati. Čovjek nije matematička formula i ne može doživjeti potpuni redukcionizam u stroj.[65]

Ipak, organska tehnologija nalik mozgu još nije ostvarena. Umjesto nje nastao je novi spoj silicija i softvera nazvan kognitivno računalstvo, zasnovano na novoj, paralelnoj, distribuiranoj, događajima pokretanoj i skalabilnoj arhitekturi[66].

4.4. Etički aspekt korištenja umjetne inteligencije u marketingu

Svijet se suočava s brzim usponom "umjetne inteligencije". Napredak u ovome polje su uvođenje strojeva s mogućnostima učenja i obavljanja kognitivnih zadataka koja je nekada bila ograničena na ljudska bića. Ovaj tehnološki razvoj nužno ima značajne društvene i kulturne posljedice.[67]

Budući da s razvojem umjetne inteligencije raste i njen utjecaj na čovječanstvo opravdano se javljaju brojna etička pitanja koja izražavaju zabrinutost u pogledu razvoja događaja u budućnosti. Zbog toga se pojavljuju sve snažniji zahtjevi da se u proces izgradnje umjetne inteligencije uključi i planiranje koje uključuje etički aspekt. To se može oslikati na primjeru autonomnih automobila koji nemaju etičke sposobnosti donošenja odluka u određenim kriznim situacijama, a gdje te situacije to zahtijevaju, pa takve probleme treba imati na umu kad se razvija takav sustav. Pritom je moguće izdvojiti nekoliko pitanja[68]:

- Kakva je budućnost u slučaju da strojevi postanu superiorniji od ljudi
- Može li doći do velike nezaposlenosti uslijed angažiranja umjetne inteligencije na brojnim poslovima?

---

[65] Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018. str.208

[66] Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018. str. 210

[67] World Commission on the Ethics of Scientific Knowledge and Technology (2019). Preliminary study on the Ethics of Artificial Intelligence. UNESCO. Dostupno na: https://unesdoc.unesco.org/ark:/48223/pf0000367823)03.03.2020). str. 3

[68] Ereš, R. Etička pitanja u razvoju umjetne inteligencije. Dostupno na: https://www.frontslobode.ba/vijesti/tehnologija/142503/eticka-pitanja-u-razvoju-umjetne-inteligencije (07.03.2020)

- Može li umjetna inteligencija ugroziti ljudske slobode i prava?
- Može li umjetna inteligencija nadvladati društvene predrasude

Više je razina izazova vezanih uz razvoj i korištenje umjetne inteligencije, a to su[69]:

- Osobna razina- na osobnoj razini se postavlja pitanje hoće li pojedinci zbog financijskog interesa pristati kreirati sustave umjetne inteligencije koji će moći djelovati na neetičan način i tako da štete ljudima ili prirodi.
- Znanstvena i edukativna razina- na znanstvenoj i edukativnoj razini se postavlja pitanje kako će se znanstvena zajednica postaviti prema razvoju etičkih načela umjetne inteligencije. Pri tom je jedno od važnijih pitanja hoće li znanstvena zajednica u slučaju da evidentiraju nepravilnosti u razvoju umjetne inteligencija ta saznanja prenijeti u javnost, te hoće li podignuti razinu edukacije opće populacije.
- Društvena razina- na društvenoj razini se postavlja pitanje kakva će etička načela razvito društvo, kako i u kojoj mjeri će to financirati, te kako će osigurati provedbu i kontrolu tih načela.

Na koncu, ostaje pitanje kakve će biti etičke posljedice ponašanja superinteligentnih sustava koji mogu ravnopravno komunicirati s ljudima na sva područja ljudskog djelovanja, od znanosti i prava do ekonomije[70]. Posebno je interesantno kako će se umjetna inteligencija pravno tretirati, postoji li mogućnost da se jednom ostvari vizija iz Zvjezdanih staza gdje komandantu Dati priznata osobnost i ljudska prava, ali i kaznena odgovornost.

Radna skupina UNESCO-a želi predložiti niz općih načela za razvoj, implementaciju i upotrebu AI. Ti principi su[71]:

- AI treba razviti i provesti u skladu s međunarodni standardi ljudskih prava.
- AI bi trebao biti uključiv s ciljem izbjegavanja pristranosti i dopuštanja raznolikost i izbjegavanje nove digitalne podjele.
- AI treba razviti kako bi se poboljšala kvaliteta života.

---

[69] Domitrović, I., Čizmić, M. (2018). Umjetna inteligencija treba etička pravila. Dostupno na: https://zimo.dnevnik.hr/clanak/umjetna-inteligencija-treba-eticka-pravila-i-vas-se-pita-koja-bi-trebala-biti---542877.html (27.02.2020)

[70] Valerjev, P. (2006). Uloga umjetne inteligencije u istraživanju uma: povijest i perspektiva. Zagreb: Institut društvenih znanosti Ivo Pilar, 2006. str. 105-122. str. 121

[71] World Commission on the Ethics of Scientific Knowledge and Technology (2019). Preliminary study on the Ethics of Artificial Intelligence. UNESCO. Dostupno na: https://unesdoc.unesco.org/ark:/48223/pf0000367823)03.03.2020) str. 25

- AI bi trebao poštivati ljudsku autonomiju zahtijevajući ljudsku kontrolu u svakom trenutku.
- AI bi trebao biti objašnjiv, uz mogućnost uvida u njegovo funkcioniranje.
- Podaci koji se koriste za obučavanje AI sustava trebaju biti transparentni.
- Osviještenost algoritama i osnovno razumijevanje rad AI je potreban za osnaživanje građana.
- Programeri i kompanije trebaju uzeti u obzir etiku u razvoju autonomnog inteligentnog sustava.
- AI treba razvijati, provoditi i koristiti u skladu s demokratskim načelima.
- AI aplikacije ne smiju imati negativnog utjecaj na okoliš

4.5. Budućnost umjetne inteligencije u marketingu

Danas se umjetna inteligencija uglavnom koristi kod rješavanja specifičnih zadataka. Predviđa se kako će tijekom četvrtoga desetljeća ovoga stoljeća zaživjeti generalna umjetna inteligencija. Njezin je dolazak izvjestan i očekivan te brojni znanstvenici iskazuju bojazan zbog načina na koji će ona utjecati na čovječanstvo. Predviđa se kako će tridesetih godina ovoga stoljeća računala biti u stanju simulirati cijeli mozak na razini neurona i sinapsi. Mreža na razini neurona i sinapsi može imati bitno veću brzinu rada od biološkoga mozga. Stoga je pitanje: „Hoće li računalo ostati sluga ili će postati gospodar mozga?“ To je ključno pitanje u suvremenim razmatranjima umjetne inteligencije[72].

AI će utjecati na prodajne procese u različitim industrijama. Većina prodavača se i dalje oslanja na telefonski poziv (ili ekvivalent) kao ključni dio prodajnog procesa. Ubuduće će prodavačima pomagati AI agent koji prati razgovore u stvarnom vremenu. Na primjer, koristeći napredne mogućnosti analize glasa, AI agent mogao bi moći zaključiti iz korisnikovog tona da navedeni problem ostaje problem i pružiti povratne informacije u stvarnom vremenu koje će usmjeravati naredni pristup (ljudskog) prodavača. U tom smislu, AI bi mogao povećati mogućnosti prodavača, ali također može izazvati nenamjerne negativne posljedice, pogotovo ako se kupci osjećaju nelagodno zbog razgovora nadziranog umjetnom inteligencijom. U budućnosti se tvrtke mogu primarno koristiti AI botovima, koji - u nekim slučajevima - funkcioniraju kao i

[72] Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018. str. 211

ljudski prodavači. Ali opasnost ostaje da, ako kupci otkriju da komuniciraju s robotom, što može izazivati negativne posljedice[73].

Poslovni model koji trenutačno koriste mrežni trgovci obično zahtijeva od kupaca da naruče proizvode nakon čega internetski trgovac isporučuje proizvode (model kupovine-otpreme). Pomoću AI-a, mrežni će trgovci možda moći predvidjeti što će kupci htjeti; pretpostavljajući da se ovim predviđanjima postiže velika točnost, trgovci na malo mogu prijeći na poslovni model otpreme-zatim-kupovine. Odnosno, trgovci će pomoću AI identificirati preferencije kupaca i otpremati predmete kupcima bez službenog naloga, pri čemu će kupci imati mogućnost vratiti ono što im ne treba. Ovaj bi pomak transformirao marketinške strategije trgovaca, poslovne modele i ponašanje kupaca (npr. pretraživanje informacija). Tvrtke kao što su Birchbox, Stitch Fix i Trendy Butler već koriste AI kako bi pokušali predvidjeti što njihovi kupci žele, s različitim stupnjevima uspjeha. Međutim, također se mora znatno poboljšati prediktivna analitika prije nego što trgovci usvoje prakse otpreme i kupovine, čime se izbjegavaju značajni povrati proizvoda i povezani negativni utjecaji. Spajajući sve to zajedno, čini se da marketinški menadžeri i istraživači trebaju uvid u ne samo konačno obećanje AI-ja, već i put i rokove duž kojih će se AI vjerojatno razvijati.[74].

AI je nesumnjivo korisna u statističkim analizama numeričkih podataka pomoću strojnog učenja. Tipičan slučaj upotrebe je primjena AI za optimizaciju cijena. Strategije određivanja cijena moraju uravnotežiti dva konkurentna problema: da je cijena dovoljno niska da privuče kupce naspram dovoljno visokih da poduzeću omogući dovoljno zarade.[75]

Lowebot u Lowe prodavaonicama kućnih poboljšanja može prepoznati klijent ime proizvoda kojeg kupac izgovori, potvrditi je li predmet na skladištu, a zatim uputit kupca na točno mjesto u trgovini na kojoj može pronaći proizvod. Ovaj zadatak zahtijeva razumijevanje i ispitivanje i brojčanih i ne numeričkih podataka, kao i unutarnje navigacijske sposobnosti. Korištenje .[76]

Marketing postaje znanost podataka. AI može riješiti stari problem "ne znam koji 50 posto mog marketinga radi". Analizirajući ogromnu količinu podataka koja je sada dostupna trgovcima,

[73] Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing Journal of the Academy of Marketing Science (2020) 48:24–42. str. 24
[74] Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing Journal of the Academy of Marketing Science (2020) 48:24–42. str. 25
[75] Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing Journal of the Academy of Marketing Science (2020) 48:24–42. str. 32
[76] Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing Journal of the Academy of Marketing Science (2020) 48:24–42. str. 32

kombinirajući ih s drugim podacima kojima obično nemaju pristup i primjenjuju strojno učenje.[77]

Očekuje se da će AI igrati važnu ulogu u predviđanju ne samo onoga što kupci žele kupiti, već i cijene koju trebaju naplatiti te treba li ponuditi promotivne cijena. Promotivne cijene su važni pokretači prodaje, pa su tako i važno područje marketinških istraživanja. Stoga se važno područje za buduća istraživanja odnosi na to kako se AI može najbolje iskoristiti za predviđanje optimalnih cijena i treba li ponuditi ili ne promotivne cijene. Drugi važan put istraživanja odnosi se na alokaciju marketinških resursa, tako što će se u budućnosti bolje predvidjeti sklonosti kupaca, pa se stoga ne bi trebale nepotrebno i uzaludno oglašavati kupcima koji su izgubljeni slučajevi.[78]

Ako se krene od sadašnjeg stanja umjetne inteligencije može se pretpostaviti kako će teći razvoj umjetne inteligencije u bliskoj budućnosti, a koji će se razgranati u pet mogućih smjerova u sljedećih deset godina[79]:

1) Specijalizirani svakodnevni proizvod bazirani na umjetnoj inteligencije koji su kapacitirani za izvođenje operacija koje ne zahtijevaju osobitu inteligenciju a o koje se najčešće niti ne percipira ka inteligentne.

2) Upotreba sustava umjetne inteligencije u obrazovanju gdje umjetna inteligencija preuzima ulogu edukatora koji se je u stanju u potpunosti adaptirati osobinama svakog pojedinog učenika.

3) Upotreba umjetne inteligencije u filtriranju informacija. U današnje svijetu postoji mnoštvo informacija vrlo različite prirode. Ljudima je teško razaznati koje su informacije točne, a koje nisu. Dodatno se postavlja i pitanje vrijednost i relevantnosti neke informacije. U takvim okolnostima ljudima je teško selektirati potrebne, točne i relevantne informacije. Upravo u rješavanju problema oko procjene točnosti i relevantnosti informacija mogu pomoći sustavi umjetne inteligencije.

4) Upotreba umjetne inteligencije u području znanosti i tehnologije će se kretati kroz daljnji razvoj ekspertnih sustava i umjetnih znanstvenika i njihova veća rasprostranjenost i široka upotreba u znanstvenim istraživanjima

---

[77] Roetzer, P. (2017). 8 Predictions for Artificial Intelligence in Marketing from AI Experts. Dostupno na: https://www.marketingaiinstitute.com/blog/8-predictions-for-artificial-intelligence-in-marketing-from-ai-experts (27.02.2020)

[78] Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing Journal of the Academy of Marketing Science (2020) 48:24–42. str. 34

[79] Valerjev, P. (2006). Uloga umjetne inteligencije u istraživanju uma: povijest i perspektiva. Zagreb: Institut društvenih znanosti Ivo Pilar, 2006. str. 105-122. str. 119

5) U upotrebi umjetne inteligencije u vojne svrhe se očekuje razvoj novih transportnih vozila i inteligentnih oružja, ali i istraživanje teško dostupnih terena kao što je svemir

5. ZAKLJUČAK

Umjetna inteligencija se odnosi na područje informatičke znanosti koja razvija računalne sustave i aplikacije čija je najvažnija osobina da su sposobne obavljati zadaće koje zahtijevaju neki stupanj inteligencije. Ti sustavi moraju biti u mogućnosti izvršavati zadatke koji zahtijevaju određenu formu i razinu inteligentnog ponašanja u smislu kolokvijalne definicije inteligencije koja pod tim pojmom podrazumijeva snalaženje u novonastalim situacijama, pri čemu treba biti u stanju prepoznati i razumjeti ljudski jezik, te imati sposobnost učenja i zaključivanja.

U suvremenim uvjetima poslovanja, kao posljedica raznovrsnih isprepletenih društvenih čimbenika, se pojavljuje nova paradigma ponašanja poslovnih organizacija koja otvara brojne prilike i izazove za sve aktere na tržištu, kako za poslovne organizacije, tako i za kupce. Kada su u pitanju potrošači to se očituje kroz njihovu sve bolju informiranost, sve veću dostupnost proizvoda, pa time i veću mogućnost izbora, općenito snažniji položaj koji im omogućuju društvene mreže, zbog čega im u konačnici jača pregovaračka moć i zbog čega oni u postaju sve zahtjevniji. Sve se to neizostavno reflektira i na poduzeća na način da poduzeća moraju tome prilagoditi sve elemente proizvodnog miksa, ali i sve druge aspekte poslovanja kako bi zadovoljili sve zahtjevnije kupce i tako održali korak sa konkurencijom..

U nastojanju da se optimiziraju marketinške operacije, poduzeća se okreću alatima i platformama koje pokreću umjetna inteligencija i strojno učenje. Na tržištu postoje brojni AI marketinški alati različitih funkcionalnosti i namjena. Područja fokusa uključuju prediktivnu analitiku, segmentaciju korisnika, automatizaciju i optimizaciju oglašavanja, chat botove za uslugu i pomoć u prodaji te personalizaciju sadržaja

AI omogućava poduzećima da pređu od jednostavnog "poznavanja" do istinskog "razumijevanja" svojih kupaca. Što više trgovci sveobuhvatnije razumiju svoje ciljne kupce, njihove simpatije i sklonosti, to je lakše, individualizirati digitalne marketinške kampanje. Tijekom određenog vremena, AI može omogućiti trgovcima da zahvaljujući inteligentnoj segmentaciji steknu osjećaj predvidljivosti u ponašanju pojedinog kupca.

Glavne značajke Ai su hyper-personalizacija kojom se postiže sveobuhvatno razumijevanje ciljane publike, veću relevantnost marketinških poruka, bolju interakcije između marki i potrošača zahvaljujući individualiziranom marketingu, smanjenje troškova, ušteda vremena zbog eliminacije obavljanja rutiniranih ponavljajućih zadataka, Bolje razumijevanje podataka o kupcima povećava učinkovitost. Smanjuje troškove, omogućuju bolje stope pretvorbe,

povećava ROI, te u konačnici uvodi poboljšane usluge i povećava zadovoljstvo korisnika Zaposlenici, zahvaljujući tome što su oslobođeni obavljanja mnogih rutiniranih poslova koje su preuzeli alati umjetne inteligencije, imaju više vremena za zadatke vezane uz kritičko mišljenje i kreativnosti.

Predviđa se kako će ubrzo računala biti u stanju simulirati cijeli mozak na razini neurona i sinapsi. Posljedično, jasno je da će AI utjecati na prodajne procese u svim sektorima. Pomoću AI-a, mrežni će trgovci moći predvidjeti što će kupci htjeti, te će nakon što AI identificira preferencije kupaca i otpremati predmete kupcima bez da ih je kupac prethodno naručio, pri čemu će kupci imati mogućnost vratiti ono što im ne treba. Očekuje se da će AI igrati važnu ulogu u predviđanju ne samo onoga što kupci žele kupiti, već i cijene koju trebaju naplatiti te treba li ponuditi promotivne cijena. Stoga se važno područje za buduća istraživanja odnosi na to kako se AI može najbolje iskoristiti za predviđanje optimalnih cijena.

Uloga ljudi u oglašavanju se ne smanjuje, već se značajno mijenja. Cilj ovih AI implementacija nije zamjena ljudi već pružanje alata za postizanje boljih rezultata. Čovjek koji pravilno koristi AI ostvarit će bolje rezultate nego što je to mogao sam postići. Ljudi koji žele izvući maksimum iz svojih marketinških napora moraju preusmjeriti svoju perspektivu da se usredotoče na svoje snage i omoguće strojevima da rade ono što najbolje rade. Baš kao što je industrijska revolucija dopustila ljudima da prekorače svoja fizička ograničenja, tako će AI omogućiti da ljudi prijeđu granice spoznaje. Ljudi nikada neće nadmašiti AI kada je u pitanju testiranje i optimizacija podataka, ali strojevi nikada neće razumjeti ljude. Nezamjenjiva uloga ljudi u suvremenom marketingu je temeljito razumijevanje drugih ljudi i pružanje boljih podataka umjetnoj inteligenciji za daljnje testiranje i optimizaciju.

Budući da s razvojem umjetne inteligencije raste i njen utjecaj na čovječanstvo opravdano se javljaju brojna etička pitanja koja izražavaju zabrinutost u pogledu razvoja događaja u budućnosti jer pogrešno usmjeren razvoj ove tehnologije može upotrijebiti ovu tehnologiju manipulativan i štetan način. Zbog toga se pojavljuju sve snažniji zahtjevi da se u proces izgradnje umjetne inteligencije uključi i planiranje koje uključuje etički aspekt.

LITERATURA

1. 7 ejemplos de aplicación de inteligencia artificial en el negocio. Dostupno na: https://mundocontact.com/7-ejemplos-aplicacion-inteligencia-artificial-negocio/ (01.04.2020)
2. Akroush, M. (2010). Transactional marketing and relationship marketing paradigms: A structural equation modelling approach. International Journal of Electronic Customer Relationship Management. 4.
3. Artificial intelligence in business. Dostupno na: https://www.nibusinessinfo.co.uk/content/examples-artificial-intelligence-use-business (01.04.2020)
4. Baker, R. (2020). Opinion: Modern marketing: AI vs. humans. dostupno na: https://sbj.net/stories/opinion-modern-marketing-ai-vs-humans,67788? (01.03.2020)
5. Biloš, A. (2012). Elektronički marketing poslovnih subjekata u Republici Hrvatskoj. Doktorska dizeratcija, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku.
6. Breault, E. (2019). 4 Ways AI Is Transforming Marketers' Roles. Dostupno na: v (02.03.2020)
7. Cannella, J, (2018). Artificial Intelligence In Marketing. Honors Thesis for Barrett, The Honors College at Arizona State University
8. Casos de uso de Inteligencia Artificial en las empresas. Dostupno na: https://www.auraportal.com/es/casos-de-uso-de-inteligencia-artificial-en-las-empresas/ (01.04.2020)
9. Contreras, A. (2020). Ejemplos de Uso de Inteligencia Artificial en los Negocios. Dsotupno na: https://tienda.digital/2019/01/04/ejemplos-de-uso-de-inteligencia-artificial-en-los-negocios/
10. Ćupić, M. (2016). Umjetna inteligencija: Umjetne neuronske mreže. Zagreb: Fakultet elektrotehnike i računarstva
11. Dalbelo Bašić, B., Čupić, M., Jan Šnajder, J. (2008). Umjetne neuronske mreže. Zavod za elektorniku, mikroelektroniku i inteligentne sustave, Fakultet elektrotehnike i računarstva

12. Davenport, T., Guha, A., Grewal, D., Bressgott, T. (2009).How artificial intelligence will change the future of marketing. Journal of the Academy of Marketing Science (2020) 48:24–42
13. Domitrović, I., Čizmić, M. (2018). Umjetna inteligencija treba etička pravila. Dostupno na: https://zimo.dnevnik.hr/clanak/umjetna-inteligencija-treba-eticka-pravila-i-vas-se-pita-koja-bi-trebala-biti---542877.html (27.02.2020)
14. Dukić, B., Gale, V. (2015). Upravljanje odnosima s potrošačima u funkciji zadržavanja potrošača. Ekonomski vjesnik : Review of Contemporary Entrepreneurship, Business, and Economic Issues, Vol. 28 No. 2, 2015.
15. Ereš, R. (2019). Etička pitanja u razvoju umjetne inteligencije. Dostupno na: https://www.frontslobode.ba/vijesti/tehnologija/142503/eticka-pitanja-u-razvoju-umjetne-inteligencije (07.03.2020)
16. Gligorijević, M. (2009). Marketing odnosa na poslovnom tržištu Marketing : časopis za marketing teoriju. Vol. 40; Broj/Issue 4, QMJED 40 (3) 125- (2009)
17. Jarek, K., Mazurek, G. (2019). Marketing and Artificial Intelligence. Central European Business Review. Vol. 8 , No. 2. 46-55.
18. Kietzmann, J., Paschen, J., Treen, E. (2018). Artificial Intelligence in Advertising: How Marketers Can Leverage Artificial Intelligence Along the Consumer Journey. Journal of Advertising Research 58(3):263-267
19. Lazcano, R. (2020). Inteligencia artificial: ejemplos de cómo puede impactar a tu negocio inteligencia artificial. Dostupno na: https://blog.enzymeadvisinggroup.com/inteligencia-artificial-ejemplos (01.04.2020)
20. Leksikografski zavod Miroslav Krleža. Hrvatska enciklopedija. dostupno na: https://www.enciklopedija.hr/ (01 02.2020)
21. Meler, Ma. (2005). Evolucija odnosa s potrošačima. Zagreb: Konferencija: XIX. Kongres CROMAR-a "Marketinške paradigme za 21. stoljeće"
22. Nexoya. AI marketing tools that you need to know. Dostupno na: https://www.nexoya.com/blog/ai-marketing-tools-that-you-need-to-know/ (01.03.2020)
23. Odden, L. 54 Artificial Intelligence Powered Marketing Tools. Dostupno na: https://www.toprankblog.com/2018/03/artificial-intelligence-marketing-tools/ (01.03.2020)

24. Permission Marketing. Dostupno na: https://searchcustomerexperience.techtarget.com/definition/Permission-Marketing (01.04.2020)
25. Pradyut V. Hande (). Can AI make marketing more human? Dostupno na: https://cio.economictimes.indiatimes.com/news/strategy-and-management/can-ai-make-marketing-more-human/66144969 (01.03.2020)
26. Prister, V. (2019). Umjetna inteligencija. Media, Culture and Public Relations, 10, 2019, 1, 67-72
27. Putica, M. (2018). Umjetna inteligencija: dvojbe suvremenoga razvoja. Hum : časopis Filozofskog fakulteta Sveučilišta u Mostaru, Vol. 13 No. 20, 2018.
28. Referal marketing. Dostupno na: https://studiousguy.com/referral-marketing-definition-strategies/ (01.04.2020)
29. Ritter,A.I. (2019). Artificial Intelligence as Enabler in the Marketing Process: A Research Agenda. Computer Science
30. Roetzer, P. (2017). 8 Predictions for Artificial Intelligence in Marketing from AI Experts. Dostupno na: https://www.marketingaiinstitute.com/blog/8-predictions-for-artificial-intelligence-in-marketing-from-ai-experts (27.02.2020)
31. Sterne, J. (2017). Artificial Intelligence for Marketing: Practical Applications. Wiley and SAS Business Serie
32. Ujević Andrijić, Ž. (2019). Osvježimo znanje, Kem. Ind. 68 (5-6) (2019) 219–220.
33. Valerjev, P. (2006). Uloga umjetne inteligencije u istraživanju uma: povijest i perspektiva. Zagreb: Institut društvenih znanosti Ivo Pilar, 2006. str. 105-122
34. VUP. Tehnike E- marketinga, dostupno na: https://www.vup.hr/_data/files/13052711478326.pdf (01.03.2020)
35. Viral marketing. Dostupno na: https://www.marketing-schools.org/types-of-marketing/viral-marketing.html (01.04.2020)
36. World Commission on the Ethics of Scientific Knowledge and Technology (2019). Preliminary study on the Ethics of Artificial Intelligence. UNESCO. Dostupno na: https://unesdoc.unesco.org/ark:/48223/pf0000367823)03.03.2020)
37. Zafeer Shahid, M., Li,G. (2019). Impact of Artificial Intelligence in Marketing: A Perspective of Marketing Professionals of Pakistan. Global Journal of Management and Business Research: EMarketingVolume 19 Issue 2 Version 1.0 Year 2019
38. Zavišić, Ž. (2011). Osnove marketinga. Visoka poslovna škola Zagreb

POPIS SLIKA

Slika 1. Razvoj i područja umjetne inteligencije 6

POPIS TABLICA

Tablica 1. Strateška gledišta transakcijskog marketinga i marketing odnosa 16

Tablica 2. Primjeri primjene AI u marketingu 23