

Utjecaj umjetne inteligencije na potrošače u marketingu

Lucić, Melita

Master's thesis / Diplomski rad

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Academy of Arts and Culture in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Akademija za umjetnost i kulturu u Osijeku**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:251:181002>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-18**



Repository / Repozitorij:

[Repository of the Academy of Arts and Culture in Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
AKADEMIJA ZA UMJETNOST I KULTURU
ODSJEK ZA KULTURU, MEDIJE I MENADŽMENT
DIPLOMSKI STUDIJ MENADŽMENT U KULTURI I KREATIVNIM
INDUSTRIJAMA

MELITA LUCIĆ

UTJECAJ UMJETNE INTELIGENCIJE NA POTROŠAČE U MARKETINGU

DIPLOMSKI RAD

MENTOR: *doc. dr. sc. Iva Buljubašić*

Osijek, 2022.

SAŽETAK

Diplomski rad "Utjecaj umjetne inteligencije na potrošače u marketingu" produkt je zanimanja za utjecaje nadolazećih promjena u tehnologiji na potrošače u marketingu. Umjetna inteligencija danas više nije toliko nepoznat pojam te se počinje koristiti u raznim sferama života. Cilj je ovog rada pružiti pregled utjecaja umjetne inteligencije na potrošače, upoznatost potrošača s umjetnom inteligencijom, kao i interakciju potrošača s alatima koji koriste bilo kakav oblik umjetne inteligencije pri svojem radu. Sukladno tome, glavni zaključci istraživanja ukazuju na to da se marketing sve više mijenja i prilagođava novim trendovima te da će umjetna inteligencija sa svojim metodama postati nezaobilazni dio marketinga. Novonastala vrsta potrošača voli provjeravati recenzije, čuti o proizvodu, vrlo dobro razgledati sve ponude te se naposljetku odlučiti za kupnju. Pri ovom procesu umjetna inteligencija može stvoriti odličan personalizirani ambijent za korisnika kako bi se korisnik osjećao pozvanim na kupnju. Moderni marketing uključuje metode umjetne inteligencije kako bi lakše profilirao kupce te, obzirom na to, stvorio personalizirani sadržaj. Osim uporabe umjetne inteligencije za profiliranje i lakšu selekciju relevantnih informacija, moderni marketing također uvodi moderne metode oglašavanja kako bi se brendovi mogli lakše približiti svojim potrošačima, stoga se u posljednje vrijeme više pažnje posvećuje marketingu na društvenim mrežama, mobilnom marketingu, kao i e-mail marketingu. Nove želje potrošača neće nestati, nego će se vremenom samo povećavati, stoga je umjetna inteligencija trenutno jedini način na koji tvrtke mogu ostati u toku s razvojem ovog vala te u toku sa sve većom potražnjom i očekivanjima svojih korisnika.

Ključne riječi: umjetna inteligencija, marketing, moderni marketing, AI u marketingu

ABSTRACT

The reason for choosing title "The impact of artificial intelligence on consumers in marketing" is a product of interest in the impact of upcoming technological changes on consumers in marketing. Artificial intelligence is no longer an unknown concept in today's world and is beginning to be used in various areas of life. The objective of this thesis is to examine the impact of artificial intelligence on consumers, consumer awareness of artificial intelligence and their interaction with tools that use some form of artificial intelligence in their work. The main conclusions of the thesis indicates that marketing increasingly changes and adapts to the new trends and because of that, artificial intelligence will become it's indispensable part. The newly emerged type of consumer always likes to look at reviews, hear about the product, take a close look at all the offers and then, after all of that, decide to buy or not. In this process, artificial intelligence can create a great personalized environment for the user, to make the user feel invited to buy. In modern marketing artificial intelligence methods are used to facilitate customer profiling and create personalized content accordingly. In addition to the use of artificial intelligence for profiling and easier selection of certain information, modern marketing is also introducing modern advertising methods to help brands reach their consumers more easily, so more attention has recently been paid to social media marketing, mobile marketing and e-mail marketing. The desires of these new consumers will not disappear but will only increase over time, therefore, artificial intelligence is currently the only way companies can survive with the development of this wave, the growing demand and expectations of their customers.

Keywords: artificial intelligence, marketing, modern marketing, AI in marketing

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

AKADEMIJA ZA UMJETNOST I KULTURU U OSIJEKU

IZJAVA O AKADEMSKOJ ČESTITOSTI

kojom ja, _____ potvrđujem da je moj diplomski rad pod naslovom _____ te mentorstvom doc. dr. sc. Ive Buljubašić rezultat isključivo mogeg vlastitog rada, da se temelji na mojim istraživanjima i oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio diplomskog rada nije napisan na nedopušten način, odnosno da nije prepisan iz necitiranog rada pa tako ne krši ničija autorska prava. Također izjavljujem da nijedan dio ovoga diplomskog rada nije iskorišten za bilo koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

U Osijeku, _____

Potpis:

SADRŽAJ

1. Uvod.....	1
2. Nastanak, pojam i značaj umjetne inteligencije.....	2
2.1. Nastanak umjetne inteligencije	2
2.2. Pojemovno objašnjenje umjetne inteligencije	4
2.3. Značaj umjetne inteligencije	5
3. Metode umjetne inteligencije.....	7
3.1. Klasične metode umjetne inteligencije	7
3.2. Moderne metode umjetne inteligencije.....	9
4. Pojam i razvitak modernog marketinga	14
4.1. Pojam marketinga.....	14
4.2. Moderni digitalni marketing	15
4.2.1. Marketing na društvenim mrežama	15
4.2.2. Mobilni marketing	16
4.2.3. Marketing putem e-maila.....	17
5. Praćenje trendova u modernom marketingu	19
5.1. Društvene mreže i aplikacije	19
5.2. Digitalni asistenti	21
6. Primjena umjetne inteligencije i njezin utjecaj na digitalni marketing.....	23
7. Uporaba i utjecaj umjetne inteligencije na potrošače u marketingu	25
8. Budućnost umjetne inteligencije u digitalnom marketingu	28
9. Istraživanje i hipoteze	31
9.1. Problem i cilj istraživanja	31
9.2. Metodologija istraživanja	31
9.3. Hipoteze	32
9.4. Rezultati ispitivanja	32
10. Rasprava.....	41
11. Zaključak.....	43
12. Literatura.....	45

1. UVOD

Digitalni marketing i online trgovina dio su industrije koja se mijenja gotovo svakodnevno. Kako sami pojmovi nagovještavaju, digitalni marketing i online trgovina odvijaju se online, stoga potrošači sve češće robu i druge potrepštine kupuju putem interneta. Nakon revolucije koju je internet donio, svakodnevno generiranje podataka dovelo je ljude do točke gdje nisu u mogućnosti sami obraditi podatke, čak niti uz pomoć tradicionalnih statističkih načina i analiza. Iz tog razloga pojavljuje se potreba za nečim novim čime će se takav posao olakšati. Zbog toga se počinje upotrebljavati umjetna inteligencija koja je otvorila mnoga vrata, kako u marketingu, tako i u drugim sferama. Umjetna inteligencija evoluirala je te tako utjecala na način na koji se marketing provodi. Ona, kao alat, ima mogućnosti mnogo toga analizirati, pogotovo potrošače od kojih je svaki jedinstven. Budući da se ponašanja potrošača razlikuju, brendovi pokušavaju što točnije predvidjeti u kojem smjeru ona idu te se tako bore pružiti bolju uslugu kupcima. Pri tome se koriste umjetnom inteligencijom s namjerom stvaranja personaliziranog sadržaja za svakog kupca.

Cilj ovog diplomskog rada jest istražiti primjenu umjetne inteligencije u marketingu te njezin utjecaj na potrošače, odnosno samu svjesnost potrošača o umjetnoj inteligenciji. Pri izradi diplomskog rada i pisanju teorijskog dijela rada korištene su knjige, časopisi, znanstveni članci te internet izvori. Za izradu istraživačkog dijela rada korištena je anketa izrađena putem *Google* obrazaca. Anketom su se željeli ispitati stavovi ispitanika o tvrdnjama koje se odnose na pojmove vezane uz umjetnu inteligenciju, marketing te ulogu i utjecaj umjetne inteligencije na kupovne odluke ispitanika.

Rad je podijeljen u jedanaest poglavlja te počinje s uvodom, a završava sa zaključkom. Poglavlja između obuhvaćaju: nastanak umjetne inteligencije, njezino značenje, metode, pojam i razvitak modernog marketinga, praćenje trendova u marketingu, praćenje trendova u digitalnom marketingu, primjenu umjetne inteligencije u digitalnom marketingu, utjecaj umjetne inteligencije na potrošače u marketingu, budućnost umjetne inteligencije u marketingu, istraživanje i hipoteze te raspravu. Za izradu rada koristile su se: metoda analize, metoda indukcije i dedukcije, metoda deskripcije, metoda kompilacije, metoda dokazivanja te anketiranje.

2. NASTANAK, POJAM I ZNAČAJ UMJETNE INTELIGENCIJE

Umjetna inteligencija nije nova pojava u svijetu, no čini se da ljudi nisu dovoljno svjesni koliko je utjecajna na njihovu okolinu. Pojmovno, umjetna inteligencija jest sposobnost digitalnog računala ili računalno kontroliranog robota i njegova mogućnost obavljanja zadataka koji se najčešće povezuju s inteligentnim bićima. Ovaj pojam ima široku primjenu u projektima razvoja sustava koji su obdareni intelektualnim procesima inače karakterističnim ljudima, primjerice sposobnošću otkrivanja značenja, rasuđivanja, ekstrapolacija iz prošlih iskustava ili generaliziranja. Otkad su se počela razvijati digitalna računala u 1940-im godinama, uočilo se kako programiranjem mogu izvršavati vrlo složene zadatke, kao što je primjerice otkrivanje dokaza matematičkih teorema ili igranje šaha.

2.1. NASTANAK UMJETNE INTELIGENCIJE

Jedan od najranijih značajnih radova na području umjetne inteligencije izradio je britanski logičar i pionir računala po imenu Alan Mathison Turing sredinom 20. stoljeća. On je 1935. godine opisao apstraktni računalni stroj koji se sastojao od neograničene memorije i skenera koji se mogao kretati naprijed-nazad kroz memoriju čitajući sve što pronade, simbol po simbol i zapisujući daljnje simbole. Radnje skenera diktirao je program instrukcija koji se također pohranjivao u memoriju putem simbola. To je bio Turingov koncept pohranjenog programa, a u njemu je postojala implicitna mogućnost da stroj radi na vlastitom programu i tako modificira ili poboljšava svoj program. Ova Turingova koncepcija sada je poznata pod jednostavnim nazivom – Turingov stroj. Fascinantno je da su sva moderna računala univerzalni Turingovi strojevi. (Coperland: Artificial intelligence. Pristupljeno 18.2.2022.)

Za vrijeme Drugog svjetskog rata Turing se nije mogao u potpunosti okrenuti svojem projektu izgradnje elektroničkog računalnog stroja s pohranjenim programom, sve do prestanka neprijateljstva u Europi 1945. godine. Ipak, za vrijeme rata Turing je i dalje razmišljao o strojnoj inteligenciji, što je potvrdio jedan od Turingovih kolega, Donald Michie (kasnije osnivač Odjela za strojnu inteligenciju i percepciju na Sveučilištu u Edinburghu), kada je izjavio kako se sjeća da je Turing često raspravljao o temi kako računala mogu učiti iz

iskustava i rješavati nove probleme korištenjem vodećih principa, danas poznatih kao heurističko¹ rješavanje problema. Turing je nedugo nakon rata održao vjerojatno najranije javno predavanje (London, 1947.) u kojem je spomenuo računalnu inteligenciju govoreći kako je ono što želimo stroj koji može učiti iz iskustva i s mogućnošću dopuštanja stroju da po vlastitim uputama izradi svoj mehanizam. Godine 1948. predstavio je mnoge koncepte o umjetnoj inteligenciji u izvješću pod naslovom „Intelligentni strojevi“, ali nažalost nije objavio ovaj rad te su kasnije do mnogo njegovih ideja i zaključaka došli i drugi. (Coperland: Artificial intelligence. Pristupljeno 18.2.2022.)

Spomenuvši Turinga, bitno je naglasiti i 1950. godinu kada je Turing zaobišao tradicionalne rasprave o definicijama inteligencije, uvodeći praktični test računalne inteligencije koji je danas poznat pod nazivom Turingov test. Ovaj je test „dizajniran da stvori efikasnu operacijsku definiciju inteligencije. Računalo može uspješno položiti test ako ljudski ispitivač, u odvojenoj sobi, nakon što postavi pitanja u pisanom obliku, ne može razaznati da li je odgovor došao od računala ili ljudske osobe.“ (Anonymus: Definicija umjetne inteligencije. Pristupljeno 18.2.2022.) Kao što je navedeno, sva komunikacija odvija se putem tipkovnice i zaslona. Ispitivač može postavljati široka pitanja, a računalu je dopušteno učiniti sve što je moguće da prisili pogrešnu identifikaciju. Godine 1991. američki filantrop Hugh Loebner pokrenuo je godišnje natjecanje za Loebnerovu nagradu, obećavajući isplatu od 100 000 dolara prvom računalu koje prođe ovaj test i također dodjeljujući 2000 dolara svake godine onima koji su se najviše trudili. Međutim, niti jedan program umjetne inteligencije tada nije došao ni blizu uspješnom rješavanju Turingovog testa. (Coperland: Artificial intelligence. Pristupljeno 18.2.2022.)

Iako je Turing već u 30-ima počeo spominjati i raditi na umjetnoj inteligenciji, kao što su i prije njega klasični filozofi pokušali opisati ljudsko mišljenje kao simbolički sustav, područje umjetne inteligencije nije bilo formalno prepoznato i utemeljeno sve do 1956. godine kada je osmišljen pojam umjetne inteligencije „na Dartmouth Collegeu, koji je, okupivši pionire toga područja, potaknuo sustavna istraživanja. Taj je kongres organizirao John McCarthy koji je potom postao autor osnovnog programskog jezika umjetne inteligencije LISP-a (1958.) te ga se danas smatra začetnikom umjetne inteligencije. Nakon početnih optimističnih prognoza, u 1960-ima je sva složenost postizanja umjetne inteligencije koja bi

¹ heuristika (prema grčki εὐρίσκειν: nalaziti, otkrivati), postupak koji vodi prema otkriću ili ga potiče. (Hrvatska enciklopedija: Heuristika. Pristupljeno 18.2.2022.)

bila mjerljiva s ljudskom izašla na vidjelo te su se istraživanja usmjerila prema parcijalnim rješenjima pojedinih problema. Tako je 1961. razvijen šahovski program koji je igrao na razini majstora, 1965. stroj koji se koristio rezolucijom kao metodom logičkoga zaključivanja, a iste godine započeo je rad na glasovitom ekspertnom sustavu Dendral. Početkom 1970-ih razvijen je programski jezik PROLOG te potom prvi zaista upotrebljivi ekspertni inteligentni sustavi, kakav je bio sustav MYCIN, koji je mogao dijagnosticirati bakterijske krvne infekcije i preporučiti liječenje.“ (Hrvatska enciklopedija: Umjetna inteligencija. Pristupljeno 18.2.2022.) Postizanje i izrada umjetno inteligentnog bića nije bila jednostavna. Nakon mnogo izvještaja u kojima se kritizirao napredak u ovoj sferi, financiranje vlade i interesi počeli su opadati te se zbog toga razdoblje od 1974. do 1980. godine prepoznaje kao "zima umjetne inteligencije". Ovo područje ponovo je zaživjelo 1980-ih godina kada je britanska vlada iznova počela dijelom financirati ovakve projekte kako bi se uspješno natjecali s konkurencijom Japana. Istraživanja su nakon toga opet imala svoje uspone i padove, sve do 1997. godine kada je IBM-ov Deep Blue postalo prvo računalo koje je pobijedilo šahovskog prvaka i velemajstora Garryja Kasparova. Godine 2011. sustav za odgovore na pitanja Watson pobijedio je u kvizu "Jeopardy!" pobijedivši tada aktualne prvake Brada Ruttera i Kena Jenningsa. (Lewis, 2014: A Brief History of Artificial intelligence. Pristupljeno 18.2.2022.)

Obzirom na nastanak i razvitak ovoga pojma, budućnost koju donosi postavlja visoka očekivanja. Stručnjaci navode kako će uspon umjetne inteligencije većini ljudi bolje „sjesti“ tijekom ovog desetljeća, ali su mnogi zabrinuti kako će napredak u ovoj sferi utjecati na to što znači biti čovjek, biti produktivan i imati slobodnu volju. (Anderson, Rainie, 2018: Artificial Intelligence and the Future of Humans. Pristupljeno 18.2.2022.)

2.2. POJMOVNO OBJAŠNJENJE UMJETNE INTELIGENCIJE

Umjetna inteligencija jest simulacija procesa ljudskog razmišljanja, odnosno inteligencije uz pomoć strojeva, tj. računalnih sustava. Specifične primjene umjetne inteligencije uključuju razne ekspertne sustave, obradu prirodnog načina govorenja i jezika, prepoznavanje govora, kao i strojni vid. Općenito, sustavi umjetne inteligencije rade na način da unose velike količine označenih podataka prikupljenih tijekom treninga i zatim analiziraju te podatke za korelacije i obrasce te ih naposljetku koriste za predviđanje budućih stanja. Točno

na ove načine, *chatbot*, koji dobiva primjere tekstualnih razgovora iz raznih izvora, može naučiti prilagoditi svoj način komunikacije i primjene tekstualnih poruka koje nalikuju na realistične razmjene poruka među ljudima. Osim toga, ovi podaci mogu se koristiti i kao alati za prepoznavanje slika, gdje sustav može naučiti identificirati i opisati objekte na slikama pregledavajući milijune primjera. Programiranje umjetne inteligencije najviše se fokusira na tri kognitivne vještine, a to su: učenje, zaključivanje i samoispravljanje. (Burns, Laskowski, Tucci, 2022: What is artificial intelligence (AI)? Pristupljeno 18.2.2022.) Što se tiče definicije po knjizi, Hrvatska enciklopedija (mrežno izdanje) definira umjetnu inteligenciju kao „dio računalne znanosti (informatike) koji se bavi razvojem sposobnosti računala da obavljaju zadaće za koje je potreban neki oblik inteligencije, tj. da se mogu snalaziti u novim prilikama, učiti nove koncepte, donositi zaključke, razumjeti prirodni jezik, raspoznavati prizore i dr.“ (Hrvatska enciklopedija: Umjetna inteligencija. Pristupljeno 18.2.2022.) Pojam umjetne inteligencije također se upotrebljava za razna označavanja, poput svojstava neživih sustava koji imaju znakove inteligencije. Nazivaju se inteligentnim sustavima, a „obično su to računalni sustavi, dok se izraz katkad neutemeljeno primjenjuje na robote, koji nisu nužno inteligentni. Inteligentnim sustavom smatra se svaki sustav koji pokazuje prilagodljivo ponašanje, uči na temelju iskustva, koristi velike količine znanja, pokazuje svojstva svjesnosti, komunicira s čovjekom prirodnim jezikom i govorom, dopušta greške i nejasnoće u komunikaciji ili dr.“ (Hrvatska enciklopedija: Umjetna inteligencija. Pristupljeno 18.2.2022.)

2.3. ZNAČAJ UMJETNE INTELIGENCIJE

Umjetna inteligencija ima veliku važnost jer može dati poduzećima uvid u njihove projekte i operacije kojih možda ranije nisu bili svjesni, a i iz razloga što umjetna inteligencija, u nekim slučajevima, može zadatke obavljati preciznije i bolje nego ljudi, osobito kada se radi o ponavljajućim zadacima te orijentalnim detaljima, kao što je analiza velikog broja pravnih dokumenata kako bi se osiguralo da su relevantna polja ispravno popunjena. Alati umjetne inteligencije svoje poslove često završavaju vrlo brzo i to s jako malim brojem pogrešaka ili bez njih. Ovakvi rezultati pomogli su potaknuti eksploziju učinkovitosti i otvorili vrata potpuno novim poslovnim prilikama za mnoga poduzeća. Gledajući u prošlost, prije sadašnje široke primjene umjetne inteligencije bilo bi teško zamisliti korištenje računalnih softvera za povezivanje primjerice ljudi s vozačima taksija, no u današnje vrijeme je tvrtka *Uber* upravo

time postala jedna od najvećih na svijetu. Ova tvrtka, kao i mnoge u ovoj sferi, koristi se sofisticiranim algoritmima strojnog učenja za predviđanje vremena kada će ljudi vjerojatno trebati vožnju na određenim područjima, što pomaže u aktivaciji vozača te njihovom dolaženju na ta područja prije nego što ih ljudi zatrebaju. Kao drugi primjer, *Google* je postao jedan od najvećih „igrača“ za niz online usluga koristeći strojno učenje kako bi uspješno razumio načine na koje ljudi koriste njihove usluge te ih zatim poboljšao. (Burns, Laskowski, Tucci, 2022: What is artificial intelligence (AI)? Pristupljeno 18.2.2022.)

Umjetne neuronske mreže i tehnologije umjetne inteligencije dubokog učenja brzo se razvijaju, prvenstveno zbog toga što umjetna inteligencija može brže obraditi velike količine podataka i tako učiniti točnija predviđanja nego što je to ljudski moguće. Tolika količina podataka koja se stvara na dnevnoj bazi iscrpila bi istraživače te se zbog toga koriste aplikacije umjetne inteligencije koje koriste strojno učenje te mogu podatke brzo pretvoriti u informacije koje se mogu primijeniti. (Burns, Laskowski, Tucci, 2022: What is artificial intelligence (AI)? Pristupljeno 18.2.2022.)

3. METODE UMJETNE INTELIGENCIJE

Prvi pristupi umjetnoj inteligenciji ponajviše su bili usmjereni na klasične metode koje su formirale prve faze subjekta. Tada su se posebice razmatrali sustavi temeljeni na znanju, kao i ekspertni sustavi, pogotovo zbog važnosti uzročno-posljedičnih pojava. (Warwick, 2012: 31) Kroz daljnji razvoj umjetne inteligencije nastalo je nekoliko metoda koje se mogu podijeliti na klasične metode i moderne metode. U klasične metode ubrajaju se: strojno učenje, ekspertni sustavi i rudarenje podataka, dok se u moderne metode svrstavaju: neuronske mreže, inteligentni agenti, veliki podaci i evaluacijsko računalstvo.

3.1. KLASIČNE METODE UMJETNE INTELIGENCIJE

Klasične metode predstavljale su početni pristup teoriji umjetne inteligencije pa su tako poslužile daljnjoj usporedbi s ljudskom inteligencijom. Ekspertni sustavi uvrštavaju se među sustave potpore pri odlučivanju i javljaju se na području umjetne inteligencije. Ovakvi su sustavi u mogućnosti rasuđivati činjenice u određenim domenama i raditi približno onako kako bi radio i mozak stručnjaka. Da bi se ovakav učinak postigao, stroju je prvotno potrebno znanje o određenoj domeni, kao i nekakva pravila (postavljena od strane znanstvenika i stručnjaka) koja treba slijediti kada se pojave nove informacije. Uz to je također potreban i način komunikacije s korisnikom cjelokupnog sustava. Ovakvi se sustavi nazivaju sustavi temeljeni na pravilima, odnosno sustavi temeljeni na znanju ili, općenito, ekspertni sustavi. Jedan od takvih prvih uspješnih sustava bio je *MYCIN*, medicinski sustav koji je dijagnosticirao infekciju krvi. Ovaj je sustav sadržavao otprilike 450 pravila te se za njega tvrdilo da je bolji od mnogih mladih liječnika, pa čak i dobar kao neki stručnjaci. Ovaj sustav nije imao teoretski generirana pravila, već je bio izgrađen i usavršavan intervjuiranjem brojnih stručnjaka koji su mogli davati izvještaje prema vlastitim iskustvima. Prema Hrvatskoj enciklopediji, klasični ekspertni sustavi „slijede postupak logičke dedukcije koji se odvija u koracima (ciklusima) obuhvaćajući početno, ciljano te cio niz trenutačnih stanja. Zaključak ili odluka donosi se uspoređivanjem trenutačnih stanja s općim, uzročno-posljedičnim odnosima pohranjenima u bazi znanja. Postupak zaključivanja može slijediti obrazac ulančavanja unaprijed ili unatrag. Polazeći od početnog stanja, ulančavanjem unaprijed u koracima se kroz dijalog s korisnikom

sužava skup mogućih rješenja, sve do ciljanog stanja. Dvojbene situacije rješavaju se uz primjenu pravila iz baze znanja s višim oznakama izvjesnosti.“ (Hrvatska enciklopedija: ekspertni sustavi. Pristupljeno 22.2.2022). Obzirom na svoju obuhvatnost, ekspertni sustavi „primjenjuju se u nekim područjima industrije, ekonomije, medicine i sl. Iako se očekuje njihov daljnji razvoj, sustavi posjeduju i određena ograničenja. Snažno su ovisni o ugrađenoj bazi znanja, čime im je ograničena sposobnost prilagodbe tijekom uporabe. Te nedostatke pokazuju u manjoj mjeri slični sustavi, tzv. neuronske mreže.“ (Hrvatska enciklopedija: ekspertni sustavi. Pristupljeno 22.2.2022.)

Poznato je da mnogi ljudi imaju zablude o računalima, kao što je primjerice zablada da računala nisu u stanju učiti i prilagoditi se novim mogućnostima. Naravno, istina je da to može biti slučaj za određena računala koja su striktno programirana na rad samo tako kako im je i naznačeno. Ipak, strojno učenje, koje je također jedna od klasičnih metoda umjetne inteligencije, pokazuje kako mnoga računala mogu učiti iz iskustva te tako značajno poboljšati i promijeniti svoj način rada. PCCHIP u svome članku iz 2018. godine pokušava dočarati što je strojno učenje putem primjera. „Recimo da želimo program koji može razlikovati slike jabuka od slika banana. Prvo mu damo nekoliko označenih primjera jednog i drugog, a on na njima traži uzorke kako bi ih zapamtio. Nakon toga, kad mu damo neoznačene slike, on koristi ova sjećanja da bi odredio što je jabuka, a što banana, bez da mu mi pomažemo.“ (Što je to "machine learning" ili strojno učenje? Pristupljeno 22.2.2022.) Dakle, u razvoju umjetne inteligencije veliku važnost zauzima sposobnost računala za učenje. Fascinantno je što ljudi danas nisu u potpunosti svjesni da su u svakodnevnom doticaju s umjetnom inteligencijom. PCCHIP u svome članku iz 2018. godine navodi listu primjera aplikacija i uređaja koji se koriste umjetnom inteligencijom, a to su:

- „– *Google* koristi strojno učenje da poboljša preciznost rezultata traženja,
- *Facebook* vam prikazuje postove ovisno o vašim interesima i prošlom ponašanju na društvenoj mreži,
- *Netflix* vam daje preporuke koje stvara zahvaljujući strojnom učenju,
- samovozeći automobili prate objekte iz okruženja i koriste te podatke da bi poboljšali svoje vozačke sposobnosti,
- digitalni pomoćnici koriste strojno učenje da bi unaprijedili tehnologiju prepoznavanja govora.“ (Što je to "machine learning" ili strojno učenje? Pristupljeno 22.2.2022.)

Bitno je razlikovati umjetnu inteligenciju koja je stroj koji se pretvara da je čovjek, dok je strojno učenje metoda koja se pretvara da je statistički programer. Dakako, za upravljanje ovime, u oba slučaja potreban je znanstvenik. (Sterne, 2017: 4)

Opseg informacija koje su ljudima sada dostupne daleko je preopsežan za mogućnosti ljudskog mozga te dovodi do prezasićenosti informacijama. Mnoge tvrtke postoje upravo zbog navedene svrhe, kako bi ljude savjetovale o specifičnim stvarima, primjerice cijeni – kako i gdje kupiti ono što je najbolje. Ljudi se oslanjaju na ove savjete kako bi oni odradili takoreći teško obrađivanje informacija za njih. Čak i pri kupnji jednostavnih proizvoda, ljudi se susreću s mnoštvom različitih vrsta podataka, od različitih cijena, dobavljača, proizvoda s različitim sastavima i slično. Izdvajanje vitalnih dijelova znanja iz složenosti dostupnih podataka o određenoj temi naziva se rudarenje podataka. (Warwick, 2012: 54)

Najbolji je primjer rudarenja postao bliži ljudima kroz *Bitcoin*. Kako Hrvatska enciklopedija objašnjava, „*Bitcoin* nastaje tzv. rudarenjem, kao nagrada partneru u mreži čije je računalo, koristeći se snagom procesora i električnom energijom, obavilo kompliciran i vremenski zahtjevan algoritam (engl. *proof-of-work*), kojim se potvrđuju transakcije zadanoga bloka te nastaje novi blok. Iako je program za rudarenje otvorenoga koda pa svatko može sudjelovati, ono zahtijeva veliku investiciju u iznimno snažna računala i mnogo energije.“ (*Bitcoin*. Pristupljeno 22.2.2022.) Sustavi umjetne inteligencije prikladni su u ovakvim situacijama zbog sposobnosti pohranjivanja golemih količina podataka i izvlačenja svih vrsta ostalih odnosa unutar tih istih podataka kako bi se realizirali smisleni uzroci i smislene veze među tim podacima. Postoji računica koja kaže da se otprilike svake godine udvostručuje količina podataka u svijetu. Mnoga nova područja proučavanja nastaju zbog poboljšanja tehnologije koje je omogućeno i olakšano baš zbog rudarenja podacima. (Warwick, 2012: 55)

3.2. MODERNE METODE UMJETNE INTELIGENCIJE

Klasične metode umjetne inteligencije nisu toliko dobre kada je u pitanju svijest o situaciji i gruba usporedba s prethodno naučenim iskustvima, tj. kada je u pitanju nešto za što je bitna inteligencija. Mnoga stvorenja svakodnevno se susreću s značajkama inteligencije kao

što su: doživljavanje života, otkrivanje što radi, a što ne, kako se nositi s raznim situacijama na što bolji način temeljem prethodnih iskustava. Ovakve probleme moguće je bolje obraditi promatranjem kako mozak funkcionira. Prvi temeljni koncept umjetne inteligencije jest razmatranje kako biološki mozak funkcionira u njegovom osnovnom okruženju – kako uči, kako se razvija i prilagođava obzirom na vremenski period. Drugi temeljni koncept je potreba za dobivanjem relativno jednostavnih modela temeljnih elemenata mozga. Treće, temeljni elementi oponašaju tehnološki dizajn, primjerice dio električnog sklopa, kao što je računalni program čiji je cilj simulirati temeljne elemente. Temeljni elementi se zatim mogu spajati i izmjenjivati na različite načine kako bi djelovali na način koji je sličan mozgu. (Warwick, 2012: 88–89)

U temeljne moderne metode umjetne inteligencije svrstava se neuronska mreža definirana kao „sustav međusobno povezanih elemenata (nazvanih umjetni neuroni) koji služi za raznovrsna izračunavanja, zasnovan na pokušaju oponašanja rada ljudskoga mozga. Pretpostavlja se da ljudski mozak ima oko 100 mlrd. neurona, od kojih je svaki povezan s 1000 do 10 000 drugih neurona. Iako djelovanje bioloških neurona nije do kraja razjašnjeno, pokazalo se da jednostavni modeli umjetnih neurona i njihovo jednostavno povezivanje može korisno poslužiti pri rješavanju mnogih zadataka u znanosti, tehnici i u dr. primjenama.“ (Hrvatska enciklopedija: neuronska mreža. Pristupljeno 22.2.2022.) Ljudski mozak uspostavlja veze između neurona. Što je češće veza uspostavljena ili što je jača emocija koja je povezana s tom vezom, ta će veza biti jača i vjerojatno se ponovno pokrenuti. Na ovaj način radi i računalna umjetna neuronska mreža, samo na temelju matematike i, naravno, bez emocija. Svaki umjetni neuron ima svoja ograničenja kada pušta i prima signale te ako očita veliku podršku i povjerenje, veća je vjerojatnost da će signal proći uspješno. Najjednostavniji neuron može imati određeni broj ulaza i izlaza odluka, gdje je svaki ulaz vagan kako bi drukčije utjecao na tu odluku. (Sterne, 2017: 83) Obzirom na to, neuroni odabiru strukturu mreže prema zadanom zadatku, „a potom se prilagođavaju težinski faktori pojedinih veza. To se prilagođavanje naziva učenjem mreže; na ulaze mreže dovodi se niz ulaznih vrijednosti za koje su unaprijed poznate izlazne vrijednosti, pa se težinski faktori prilagođuju kako bi se izlazne vrijednosti mreže, što je moguće više, približile unaprijed poznatima. Nakon provedenog učenja na poznatom uzorku, mreža daje dobre rezultate i za druge ulazne vrijednosti. Ovisno o vrsti primjene, ulazne i izlazne vrijednosti mogu biti različito interpretirane, tj. kao binarni vektori, cijeli ili realni brojevi. Neuronske se mreže primjenjuju u zadaćama u kojima uobičajeni računalni sustavi ne daju dovoljno dobre rezultate.“ (Hrvatska enciklopedija:

neuronska mreža. Pristupljeno 22.2.2022.)

Osim umjetnih neuronskih mreža, u moderne metode pripada i evolucijsko računarstvo. Objašnjava ga Warwick (2012.) u svojem djelu "Artificial intelligence: the basics" putem primjera biološkog evolucijskog procesa, gdje u jednom trenutku postoji populacija pojedinaca u vrsti tvoreći generaciju. Jedinke iz te generacije se miješaju kako bi stvorile novu generaciju, tako da vremenom vrsta opstaje i uspijeva. Obzirom na promjene okoliša, vrsta se, sukladno tome, isto tako mora prilagoditi promjenama kako bi opstala. Gledajući na te promjene, takav proces iznimno je spor i traje godinama, no Warwick ističe kako kopiranjem, točnije modeliranjem nekih općih procesa na računalu uključenih u takav biološki oblik evolucije, postoji mogućnost pronalaska tehnike koja prilagođava, to jest poboljšava rješenje problema uz pomoć umjetne inteligencije od populacije potencijalnih rješenja koje je u krajnosti najbolje moguće ili funkcionalno rješenje. Različita rješenja, obzirom na populacije, vremenom se miješaju kako bi se proizvela nova poboljšana generacija. Rješenja u novoj generaciji također se ponovno miješaju na više načina kako bi se realizirala sljedeća generacija i tako unedogled. Zbog toga se generacije računala mogu stvoriti u mnogo kraćem vremenskom obujmu te se ne mora čekati milijarda godina da se pojavi najbolje ili funkcionalno rješenje. Također, Grundler u svojem djelu "Evolucijski algoritmi (1) Pobude i načela" komentira kako su evolucijski algoritmi "postupci optimiranja, učenja i modeliranja koji se temelje na mehanizmu prirodne evolucije. To su formalni sustavi koji nastoje biti izomorfni s prirodnom evolucijom. Evolucijski algoritmi nastali su iz dviju pobuda: želje za boljim razumijevanjem prirodne evolucije i pokušaja primjene načela prirodne evolucije pri rješavanju različitih zadaća." (Grundler, 2001: 13)

Nadalje, još jedna skupina u modernim metodama jesu inteligentni agenti. Ovaj se pojam definira kao računalni program koji ima planirano djelovanje te autonomno poduzima određene radnje kako bi postigao promjene i bio u mogućnosti ostvariti svoje ciljeve. Inteligentni agenti mogu biti "bilo koji entitet ili objekti poput ljudi, softvera, strojeva. Ovi agenti imaju sposobnosti poput rješavanja problema u stvarnom vremenu, analize brzine ili uspjeha i pretraživanja informacija." (Hr-Education-wiki.com: Inteligentni agenti. Pristupljeno 28.2.2022.) Inteligentni agenti mogu doći u različitim oblicima te ih se prema tome svrstava u tri grupe, a to su: ljudski, robotski i softverski agenti. Ljudski agent koristi se očima, nosom, jezikom, kao i ostalim osjetilnim organima kao svojim senzorima kako bi prikupio okolne informacije te također koristi udove i glasnice kao pokretače za izvršavanje radnji prema

prikupljenim informacijama. Robotski agenti kao svoje senzore koriste infracrvene radare i kamere za pridobivanje informacija iz okoliša te koriste refleksne motore kao pokretače za vraćanje impulsa i reakcija u okoliš. Ovi su agenti, obzirom na raspon svojih sposobnosti i opseg inteligencije, razvrstani u pet vrsta:

1. jednostavni refleksni agenti
2. agenti temeljeni na modelima
3. agenti temeljeni na ciljevima
4. komunalni agenti
5. agenti za učenje.

(Hr-Education-wiki.com: Inteligentni agenti. Pristupljeno 28.2.2022.)

U pravilu, može se zaključiti kako je krajnji cilj inteligentnih agenata “obavljati zadatke koje inače ljudi moraju obavljati. Agenti djeluju poput inteligentnog pomoćnika koji može omogućiti automatizaciju ponavljajućih zadataka, pomoći u sakupljanju podataka, učiti iz okoline i davati preporuke za pravi put djelovanja koji će pomoći u postizanju ciljnog stanja. Inteligentni agenti danas su u neizmornoj uporabi, a njihova će se upotreba u budućnosti samo proširiti.” (Hr-Education-wiki.com: Inteligentni agenti. Pristupljeno 28.2.2022.)

Kao zadnja od metoda moderne umjetne inteligencije može se navesti pojam veliki podaci. Vaishali u svojem članku piše kako “u ovom digitalnom svijetu s tehnološkim napretkom svakodnevno razmjenjujemo velike količine podataka poput Terabajti ili Petabajti. Ako svakodnevno razmjenjujemo tu količinu podataka, onda je također moramo održavati i negdje pohraniti. Rješenje za rukovanje velikim količinama podataka velike brzine i različite raznolikosti je veliki podaci.” (No date: Vodič za velike podatke za početnike | Što su veliki podaci? Pristupljeno 28.2.2022.) Nadalje, kroz svoj članak Vaishali opisuje kako veliki podaci mogu rukovati složenijim podacima “iz više izvora, poput različitih baza podataka, web stranica, widgeta itd. Također, može povezivati i podudarati podatke koji dolaze iz različitih izvora. Doista omogućuje brži pristup podacima (na primjer, društveni mediji).” (No date: Vodič za velike podatke za početnike | Što su veliki podaci? Pristupljeno 28.2.2022.) Dakle, veliki podaci odgovorni su za upravljanje, rukovanje i obradu velikih i različitih količina podataka koji mogu biti strukturirani, polustrukturirani ili nestrukturirani. Pojedine tehnike velikih podataka omogućuju dugo spremanje velike količine podataka te, obzirom na to, omogućuju i lakše rukovanje primjerice povijesnim podacima te, osim toga, mogu

generirati i točna izvješća. Brzina obrade podataka putem ove metode je nevjerojatna te se njezina primjena može najčešće uočiti na društvenim medijima. Veliki podaci također omogućuju korisnicima da svoje poslovne odluke donose učinkovitije. Obzirom na spomenute stvari, važno je shvatiti koliko ova metoda ima izazova i rizika. Jedan od glavnih rizika i izazova jest pravilno upravljanje ovakvom metodom. Kako Vaishali navodi “na primjer, da bi se generiralo izvješće koje sadrži posljednjih 20 godina podataka, potrebno je spremati i održavati zadnjih 20 godina podataka sustava. Da bi se osiguralo točno izvješće, u sustav je potrebno unijeti samo relevantne podatke. Ne bi trebao sadržavati nebitne ili nepotrebne podatke, inače će održavanje takve količine podataka biti velik izazov za tvrtke.” (No date: Vodič za velike podatke za početnike | Što su veliki podaci? Pristupljeno 28.2.2022.) Nadalje, još jedan od velikih izazova ove metode bila bi sinkronizacija različitih vrsta podataka koji dolaze iz različitih izvora te se, obzirom na to, stvara problematika i u konzistentnosti tih podataka. Osim ovih problema, može se reći da je rukovanje ovom tehnologijom poprilično skupo kao i prikupljanje, agregiranje, analize i pohrana samih podataka.

4. POJAM I RAZVITAK MODERNOG MARKETINGA

Prema Hrvatskoj enciklopediji, marketing se definira kao “proces planiranja i provođenja stvaranja ideja, proizvoda i usluga, određivanja njihovih cijena, promocije i distribucije kako bi se obavila razmjena koja zadovoljava ciljeve pojedinaca i organizacija.” (Hrvatska enciklopedija: Marketing. Pristupljeno 1.3.2022.) Moderni marketing ne razlikuje se previše od prvotne definicije marketinga. On ima usmjerenost za iskorištavanjem pune mogućnosti poslovanja kako bi se klijentu pružilo najbolje iskustvo i time potaknuo rast. Moderni marketing može se definirati kao holistička i prilagodljiva metodologija koja povezuje brendove sa stvarnim kupcima i dovodi do poslovnih rezultata koristeći se modernim strategijama, kreativnošću, tehnologijom i analizom.

4.1. POJAM MARKETINGA

Marketing je dio poslovne strategije koji je neophodan za sve, bez obzira o kojoj grani posla se radilo. Može se definirati kao karika koja spaja kupce i prodavače ili pružatelje usluga. Najveća zablude pri razumijevanju samog pojma marketinga jest misliti kako je prodajom usluge ili proizvoda proces gotov. Naprotiv, zadovoljavanjem potreba kupaca treba se stvoriti dugotrajna vjernost kupaca te samim time i porast potražnje za određenim proizvodom. Osim toga, vrlo je bitno proizvod dobro prezentirati, odrediti ciljne skupine, prikupiti povratne informacije i reagirati na njih. Nadalje, marketing je administrativni i ”socijalni proces jer intervenira grupa ljudi koja treba i želi ponuditi i razmjenjivati proizvode sa zajednicom, a administrativna je jer je potrebno planirati, organizirati i provoditi različite prijedloge i ideje kako bi se postigao uspjeh tvrtke. Glavna je funkcija marketinga u načelu odrediti što ljudi žele ili ne žele i, odatle, razviti proizvodnju ili uslugu. To jest, marketing proučava potrebe potrošača, a zatim ga učinkovito zadovoljava.” (Anonymous, 2022: Marketinško značenje (Što je to, pojam i definicija) – Izrazi. Pristupljeno 1.3.2022.)

4.2. MODERNI DIGITALNI MARKETING

Napredak tehnologije sa sobom povlači napredak u drugim sferama te tako i u marketingu. Napretkom interneta i širenjem društvenih i socijalnih mreža pojavljuje se marketinški koncept gdje se “traži pristup potrošačima i kupcima praćenjem mišljenja o proizvodima i uslugama koje nudi tvrtka.” (Anonymous, 2022: Marketinško značenje (Što je to, pojam i definicija) – Izrazi. Pristupljeno 1.3.2022.) Digitalni marketing odnosi se na primjenu marketinških strategija u digitalnim medijima različitih oblika te obuhvaća odnose s javnošću, oglašavanje i komunikaciju ili, preciznije, sve vrste strategija putem digitalnih medija. Oreški u svom članku "Što je digitalni marketing" objašnjava: “Digitalni marketing radite ako – komunicirate s vašim kupcima preko bilo kojeg digitalnog kanala (od *Googlea* do *e-maila*) i nudite bilo koje proizvode. Svugdje ćete naići na razne članke i definicije, ali jedno je sigurno; da bi digitalni marketing uopće funkcionirao, trebamo:

1. struju (voda i plin vam ne trebaju)
2. jedan od uređaja (laptop, stolno računalo, tablet, pametni telefon...)
3. upoznati kupce putem digitalnih kanala
4. analizirati sve što radimo
5. testirati, testirati, testirati i onda još malo testirati.“

(Oreški, 2016. Pristupljeno 18.2.2022.)

Nadalje, u svome članku Oreški navodi kako je digitalni marketing potreban u današnje vrijeme jer to više nije samo budućnost, nego se događa već u sadašnjosti. On je ciljan, mjerljiv, pun paradoksa i interaktivan te se može razvrstati u nekoliko cjelina, no ovaj rad dotiče samo neke od njih, a to su: marketing na društvenim mrežama, mobilni marketing te marketing putem e-maila.

4.2.1. MARKETING NA DRUŠTVENIM MREŽAMA

Društvene mreže smatraju se jednim od najvažnijih sredstava u digitalnim marketinškim kampanjama. Komunikacija ovim putem odvija se brzim i lako prilagodljivim načinom za povezivanje s klijentima. Neke od najvažnijih društvenih mreža koje se trenutno

koriste i u kojima je vidljiva primjena ovakvih kampanja jesu: *Facebook*, *LinkedIn*, *Twitter* te *Instagram*. Ovisno o kojoj se društvenoj mreži radi, pristup je drugačiji te se prilagođava obzirom na okolinu te društvene mreže. Poznato je da različite mreže privlače različite korisnike s različitim interesima te se zbog toga mogu lakše odabrati i formirati određene ciljne skupine. Naravno, društvene mreže pružaju korisnicima mogućnost međusobne komunikacije te saznanja o proizvodima, tuđa mišljenja, preporuke i komentare, no, uz sve navedeno, društvene mreže imaju i svoje nedostatke. Veliki nedostatak društvenih mreža jest privatnost jer je u današnje vrijeme teško zaštititi svoje privatne podatke na internetu. Brojni trendovi današnjice započinju s “prefiksom ”E-“: E-poslovanje, E-mail, E-marketing, E-oglašavanje, E-trgovina, E-bankarstvo, itd. Utopijska verzija interneta jest ”globalno selo”. Međutim, budući Web 2.0 personalizira sve moguće sadržaje na internetu te dolazi u opasnost da reflektira nas same umjesto svijeta oko nas. Online trgovine personaliziraju naš odabir i tako serviraju upravo naš vlastiti ukus. Tražilice personaliziraju pretraživanje riječi tako da vidljivima postaju promidžbene poruke samo za proizvode i usluge kojima se već koristimo ili koje priželjkujemo. Krug prijatelja s *Facebooka* ili druge društvene mreže ne čini ”globalno selo”, nego ”selo moje malo.” (Stanojević, 2011: 177)

4.2.2. MOBILNI MARKETING

Poznato je da se čovječanstvo sve više koristi pametnom tehnologijom, a u koju pripadaju i pametni telefoni. Broj korisnika koji pristupaju bilo kakvom sadržaju na internetu putem telefona kroz godine se povećao na čak 63 %, a 3 od 4 korisnika vrši online pretrage putem svojih mobilnih uređaja. Same ove statistike već su pokazatelj koliko je mobilni marketing postao potreban i značajan u ovo doba. Ovakav marketing podrazumijeva strategije digitalnog marketinga te ga je moguće primijeniti u svim vrstama poslovanja. Najčešće strategije koje se upotrebljavaju uz ovu vrstu marketinga jesu: mobilne aplikacije, sms marketing, mms marketing, marketing putem mobilnih igrica, qr kodovi te lokalni oglasi. (Marketing Fancier, 2018: Mobilni marketing: definicija i značaj u digitalnom poslovanju. Pristupljeno 7.3.2022.) Mobilni marketing može se podijeliti u dvije skupine, a to su “push” i “pull” marketing. “Push” marketing odnosi se na situacije gdje se sadržaj šalje potrošaču u trenutku kada potrošač to nije sam zatražio te iz tog razloga “oblici mobilnog marketinga kao što su audio poruke, SMS (engl. *Short Messaging Service*), e-mail, multimedijalne poruke,

slikovne poruke, ankete te svi drugi oblici „*push*“ oglašavanja ili sadržaja koji se prima na mobilnim uređajima ili mrežama spadaju u ovu kategoriju. Ovaj oblik mobilnog marketinga tradicionalniji je u odnosu na „*pull*“ mobilni marketing.“ (Golob, 2016: 151) Druga kategorija je „*pull*“ mobilni marketing koji „podrazumijeva jednokratno slanje sadržaja ili promotivne poruke korisniku mobilnog uređaja ili mreže nakon njegova zahtjeva za sadržajem ili porukom, ili ubrzo nakon njegova zahtjeva“. (Golob, 2016: 151) Važno je razumjeti kako mobilni uređaji nisu jedini faktor u mobilnom marketingu. Najbitniji su faktor pri mobilnom marketingu informacijske tehnologije koje se koriste putem mobilnih uređaja kao alati implementacije mobilnih strategija. Razvoj informacijske tehnologije „već je sada omogućio implementaciju novih metoda mobilnog oglašavanja i pružio brojnim poslovnim subjektima mogućnost češćeg i utjecajnijeg dohvata potrošača“. (Golob, 2016: 153) Razvojem spomenute informacijske tehnologije, došlo je i do skupljanja baza potrošača. Svaka organizacija najčešće posjeduje jedinstvenu bazu podataka o određenim ciljnim skupinama na kojima se planira bazirati te na svojim potrošačima. Takva baza „podrazumijeva grupu stalnih kupaca proizvoda i/ili usluga koja se gradi sakupljanjem osnovnih informacija o kupcima“. (Marketing Fancier, 2018: Mobilni marketing: definicija i značaj u digitalnom poslovanju. Pristupljeno 7.3.2022.) Ovakva baza trebala bi sadržavati sve bitne informacije o potrošačima, kao što su demografske, ekonomske, socijalne i mnoge druge karakteristike potrošača. Ovakve baze skupljaju se na raznolike načine, no najčešće se pribavljaju sudjelovanjima u nagradnim igrama, poklon bonovima, programima lojalnosti i slično.

4.2.3. MARKETING PUTEM E-MAILA

E-mail je popularan još i danas te je, obzirom na to, postao dobar alat za marketing. Poznato je da je bez e-maila gotovo pa nemoguće preživljavati u poslovnom svijetu, a ponekad i u privatnom. E-mail marketing može se objasniti kao slanje e-mailova „klijentima koji mogu biti trenutni ili budući. Neki od ključnih elemenata za uspješnu e-mail marketing kampanju su: izravna pošta, odnosno poruke se šalju izravno trenutnim i potencijalnim kupcima, e-mail zadržavanja, odnosno česte i redovite poruke e-maila koje se šalju trenutnim kupcima, oglasi e-poštom, odnosno oglasi za oglašavanje nalaze se u porukama e-maila koju drugi šalju.“ (Čmarec, 2019: 20–21) E-mail marketing može se definirati kao pojam koji se koristi za razne promocije usluga i proizvoda slanjem promotivnih i informacijskih sadržaja putem

elektroničke pošte. Ovaj oblik oglašavanja koristi se kako bi se izgradio odnos povjerenja između kupca i proizvođača, odnosno davatelja usluga. Svaki e-mail poslan potencijalnom ili već postojećem korisniku jest postupak e-marketinga. Ovakav marketing poprilično je zahtjevan te je ručno održavanje e-mail lista težak i naporan posao, stoga “oglašivači često koriste neki od servisa za vođenje e-mail marketing kampanja. Postoji mnogo kvalitetnih i besplatnih servisa, a jedan od najpoznatijih je *MailChimp* koji omogućuje besplatno slanje do ukupno 12 000 e-mail poruka mjesečno listi od do 2 000 e-mail adresa (korisnika).” (Anonymous, no date: E-mail marketing. Pristupljeno 7.3.2022.) U novije vrijeme, iako mnogi članci, časopisi i statistike naglašavaju korisnost, kao i potrebnost ovog načina marketinga, poznato je da velika većina korisnika zapravo ignorira ovakav način marketinga ili ga pak registriraju kao spam.

5. PRAĆENJE TRENDOVA U MODERNOM MARKETINGU

Pružanje dobrog, pozitivnog i trajnog korisničkog iskustva vrlo je bitan faktor i kritičan izazov s kojim se mnoge tvrtke susreću. Način na koji kupci i korisnici to doživljavaju brzo se i potpuno mijenja. Tehnologija koja je pristupačna mnogim korisnicima (npr. mobilni i pametni uređaji, virtualna stvarnost, dronovi, neuroznanost, automatizacija te interakcije među strojevima putem interneta) uvelike mijenja stvari i utječe na ponašanje potrošača, kao i na načine na koje se tvrtke organiziraju. Može se reći da nove tehnologije mijenjaju uloge ljudi te da su granice između čovjeka i stroja iz dana u dan sve nejasnije.

Nova tehnologija sa sobom donosi i mnogobrojna nova iskustva koja rezultiraju golemim količinama podataka, uključujući ponude, platforme, korištenje uređaja, suradnju s drugim kupcima i partnerima kroz vrijeme i prostor. Obzirom na to kroz što sve ovaj proces prolazi, pažnja potrošača je porasla te postala fragmentirana. Kontrola potrošača nad medijima koje konzumiraju postala je veća, stoga marketing stručnjaci moraju biti u toku s trendovima i inovacijama te moraju biti relevantni u stvarnome vremenu kako bi promijenili percepcije potrošača i potaknuli ih na djelovanje. Marketing stručnjaci moraju imati ono što potrošač želi ili ga usmjeriti na mišljenje da on to zapravo želi. U novom suvremenom potrošačkom svijetu marketing najbolje funkcionira kada potrošači pokušaju stupiti u razgovor ili odnose s tvrtkom jer je to ono što tada smatraju relevantnim. (N. Lemon 2016: *The Art of Creating Attractive Consumer Experiences at the Right Time: Skills Marketers Will Need to Survive and Thrive*. Pristupljeno 8.3.2022.)

5.1. DRUŠTVENE MREŽE I APLIKACIJE

Facebook je danas još uvijek najčešće upotrebljavana mreža za marketinške kampanje te i dalje drži svoje mjesto među najpopularnijim društvenim mrežama za ovakve strategije. Razne mobilne aplikacije, npr. *Facebook Messenger*, *WhatsApp* i *Viber*, danas se sve češće koriste i u poslovne, a ne samo privatne svrhe. Putem ovih aplikacija razne se tvrtke i poduzeća pokušavaju približiti svojim klijentima te tim putem poboljšati kvalitetu odnosa. Prije nego što je nastao naziv za pojam Web 2.0 1999. godine, internetske stranice sadržavale su uglavnom

statičan sadržaj, tj. tekstove i pokoji grafiku. Web-mjesta su se bazirala na tehnologiji Web 1.0, pri čemu su vlasnici web stranica bili primarni suradnici u kreiranju sadržaja. Internetske informacije bile su fokusirane uglavnom na pasivnu publiku koja je primala, ali ne i doprinosila sadržaju. Međutim, uvođenjem novih internetskih tehnologija Web 2.0 na prijelazu u 21. stoljeće, društveni mediji, kao što su primjerice blogovi, počeli su dopuštati korisnicima međusobnu interakciju i suradnju u raznolikim virtualnim zajednicama. Ova otvorenija zajednička metoda dvosmjerne komunikacije na društvenim medijima u potpunosti je suprotna s pristupom odozgo prema dolje koji je karakterizirao ranije godine weba. Točnije, društveni mediji počeli su ispunjavati karakteristike web-mjesta Web 2.0, pružajući bogato i drugačije korisničko iskustvo, dinamičan sadržaj, otvorenost, skladnost, kao i kolektivnu inteligenciju. Aktivni korisnici svih društvenih medija na internetu mogli su iskoristiti razne značajke koje su im omogućile da 'lajkaju', stvaraju i objavljuju slike te učitavaju videozapise, tekst i mnoge druge stvari. Nadalje, korisnici su mogli podijeliti te podatke s odabranom grupom prijatelja ili javno na webu. Ovo je također otvorilo mogućnosti web-mjesta društvenih medija za neželjenu poštu i trolanje od strane beskrupuloznih ili manje zrelih korisnika. Ipak, društveni mediji brzo su rasli u SAD-u i diljem svijeta zbog miješanja tehnologije i društvene interakcije za zajedničko stvaranje vrijednosti. (Social Media Marketing, lumen, no date: Introduction to Social Media and Digital Marketing. Pristupljeno 9.3.2022.)

Obzirom na navedeno, može se zaključiti da su glasovi potrošača postali sve snažniji zbog napretka društvenih medija i međusobne komunikacije koja im je omogućena zbog napretka tehnologije i interneta. Istraživači se iz ovoga razloga pokušavaju usredotočiti na angažman potrošača, njihove temeljne karakteristike, motivaciju i utjecaj ovakvih vrsta komunikacije na njihovu potrošnju i ponašanje, pri čemu se ispostavilo da su čimbenici poput angažiranosti robne marke, imidža brenda te usklađenosti imidža vlastite robne marke utjecali na ponašanje potrošača. Čini se da pojedine osobne karakteristike potrošača koje su povezane i s psihološkim pokretačima, poput samopoštovanja, zadovoljstva vlastitim životom, nekakvog narcizma i potrebe za pripadanjem u grupi ili društvu igraju važnu ulogu u načinu dijeljenja svojih namjera na društvenim online platformama. (Dwivedi et al., 2021: 3)

Promjene na društvenim platformama događaju se iz dana u dan i može se reći da su konstantne. Zbog toga istraživanje marketinga društvenih medija i metrika povezanih s društvenim medijima postaje prilično izazovno. Pojedine metrike povezane s društvenim medijima skoro pa uvijek ostaju dosljedne, kao što je primjerice broj pratitelja, lajkova i

podjela objava. Osim ovih metrika, pojavljuju se i druge korisne metrike, primjerice influenceri koji su u posljednje vrijeme počeli imati veliki utjecaj na korisnike i potrošače. Influencere se može definirati kao pojedince koji imaju mogućnosti utjecati na druge promicanjem i preporukom raznih brendova, robnih marki i tržišnih promjena putem društvenih mreža. (Dwivedi et al., 2021: 6) Influenceri su postali bitni u ovom segmentu marketinga zbog inovacije, a jedna od najvećih prednosti koju influenceri donose reklamiranjem je ta “da su se ljudi navikli na klasične reklame. One djeluju korporativno i beživotno dok kod influencera postoji povezanost. Naime, veća je šansa da ćete posjetiti neko mjesto ili kupiti neki proizvod ako vam ga prijatelj preporuči. Tu dolazimo do posebnosti influencera. Oni imaju doticaj s publikom na svakodnevnoj bazi te se nakon nekog vremena doimaju kao prijatelji, što na neki način i jesu. Pogotovo oni koji su “slučajno” postali influenceri nakon što su ih ljudi prepoznali zbog karizme, dobrog sadržaja i mnoštva drugih pozitivnih osobina.” (Markething, 2020: Što su influenceri i što sve trebate znati o njima. Pristupljeno 9.3.2022.)

5.2. DIGITALNI ASISTENTI

Digitalni asistenti, poznati i kao prediktivni *chatbotovi*², napredni su računalni programi koji simuliraju razgovore s ljudima koji ga koriste, najčešće putem interneta. Digitalni asistenti koriste naprednu umjetnu inteligenciju, razumijevanje i obradu jezika te strojno učenje kako bi uspjeli učiti tijekom rada i pružili personalizirano razgovijetno iskustvo. Kombinirajući raznolike povijesne informacije, primjerice preferencije pri kupnji, vlasništvo nad stambenim objektima, lokaciju, veličinu obitelji i slično, algoritmi mogu stvoriti modele podataka koji identificiraju obrasce ponašanja i pročišćavaju te obrasce kako se novi nadodaju. Učeći i prolazeći kroz povijest korisnika, njegovih preferencija i drugih informacija, digitalni asistenti mogu odgovoriti na složena pitanja, dati preporuke, predviđati i pokrenuti razgovore. (Oracle, no date: What Is a Digital Assistant? Pristupljeno 9.3.2022.) Najbolji primjer su digitalni asistenti poput *Appleove Siri* i *Microsoftove Cortane*, koji mogu odgovoriti na mnoga opća pitanja te ponuditi preporuke na temelju korisnikovog profila, njegovog prethodnog ponašanja i drugih informacija. Digitalni asistenti mogu pomoći pri prijavama u hotele, izbjegavanju gužvi u prometu, naručivanju hrane i pića, kupovini... Također, ako korisnik

² Chatbot: vrsta softvera koji se koristi za interakciju s ljudima na različitim jezicima putem različitih mobilnih aplikacija, web stranica, poruka itd. (Anonymous, no date: Što je Chatbot: Proces dizajniranja i njegova arhitektura. Pristupljeno 10.3.2022.)

namjerava biti odsutan izvan grada na neko vrijeme, digitalni asistent može korisniku javljati kakva je vremenska prognoza u njegovom gradu i npr. regulirati temperaturu u stanu. Osim za pojedince, digitalni asistenti u tvrtkama i poduzećima mogu pružiti jedinstvenu prikladnu točku za partnere i kupce. Digitalni asistenti u ovakvim okruženjima najčešće se koriste u telefonskim centrima za korisnike kako bi se lakše upravljalo dolaznom komunikacijom. Nadalje, ovi asistenti se koriste i za interne svrhe, kao što je treniranje novih zaposlenika.

Za IT operacije najčešće se koriste spomenuti *chatbotovi* u svrhu poboljšavanja iskustva upravljanja uslugama i automatiziranje usluga zaposlenika, čineći ih dostupnijima većem broju ljudi. Uz inteligentne *chatbotove*, zadaci koji su inače uobičajeni, poput poništavanja lozinki, ažuriranja statusa sustava, upozorenja o prekidu rada te naručivanja zaliha mogu se lagano automatizirati i učiniti dostupnima 24 sata dnevno. (Oracle, no date: What Is a Digital Assistant? Pristupljeno 9.3.2022.) Pojedincima digitalni asistenti mogu unijeti praktičnost i dozu zabave u njihove domove ili automobile. Kada se koriste u specifične svrhe, npr. upravljanje grijanjem ili sigurnošću doma, mogu uštedjeti novac korisnicima i osloboditi ih od zamornih zadataka. Poduzeća i tvrtke pronalaze mnoge prednosti u korištenju digitalnih pomoćnika, posebno pri poboljšanju učinkovitosti i pružanju pomoći svojim zaposlenicima i klijentima. Korištenje digitalnih pomoćnika tvrtkama može pomoći pri:

- ponudi više usluga putem *chatbota* koji može rukovati rutinskim službama za pomoć ili zahtjevima za korisničke službe
- uštedi novca jer digitalni asistenti omogućuju tvrtkama da se povežu s klijentima i zaposlenicima na osobnoj razini bez vremena i troškova živih predstavnika
- olakšavanjem zadataka, odnosno brizi o suvišnim zadacima ili pak skraćujući vrijeme potrebno za obavljanje osnovnih zadataka te tako digitalni asistenti olakšavaju posao osoblju i zaposlenima
- pružanju boljih usluga – kupci i zaposlenici cijene normalne ‘prirodne’ razgovore u praktičnim aplikacijama koje služe za razmjenu poruka te preferiraju brze i točne odgovore na svoja pitanja
- izbjegavanju pogrešaka – digitalni asistenti mogu predvidjeti nadolazeće događaje te samim time uputiti i poslati podsjetnike
- poboljšanju poslovanja – digitalni asistenti uče vremenom i iskustvom te prikupljaju podatke u stvarnom vremenu koje tada tvrtke mogu koristiti za svoje kontinuirano poboljšanje korisničkoga iskustva i učenje o zaposlenima i klijentima.

(Oracle, no date: What Is a Digital Assistant? Pristupljeno 9.3.2022.)

6. PRIMJENE UMJETNE INTELIGENCIJE I NJEZIN UTJECAJ NA DIGITALNI MARKETING

Istraživanje tržišta postalo je sredstvo za utvrđivanje koliko je tržište veliko za novi izum ili posebnu uslugu koju tvrtka planira plasirati. Osim toga, istraživanje tržišta služi i za saznanje ima li dovoljno ljudi unutar ciljane regije koji bi si to mogli priuštiti. Prilikom navedenog postavljaju se sljedeća pitanja: Postoje li konkurenti na ovom području? Uočavaju li ljudi već potrebu za tim ili se treba utrošiti vremena na obrazovanje ljudi o nadolazećem proizvodu ili usluzi? Kakve alternative postoje? Radijskim i televizijskim postajama bila je potrebna demografija kako bi opisali svoju publiku potencijalnim oglašivačima. Prvotni podatci bili su: dob, spol, stupanj obrazovanja i slično. Pokrenuti su nacionalni popisi stanovništva, a nedugo zatim pojavile su se i tvrtke koje su provodile detaljnija istraživanja. Uskoro su se tražile prilagođene ankete o specifičnoj svijesti i robnim markama, atributima i afinitetima. Istraživanje tržišta putem telefonskih intervju, anketa, međuspremnik trgovačkih centara i izravnog odgovora putem pošte smanjio je rizike ulaganja. S vremenom se mogao steći uvid u to je li brend bio visoko ili nisko na skali ciljane publike. Mogao se predvidjeti i potencijalni uspjeh pokretanja novih ponuda. (Sterne, 2017: 128)

Kako se inteligencija strojeva razvija i poboljšava iz dana u dan, vrijednost čovjekove vještine predviđanja će se smanjiti, budući da strojno predviđanje pruža jeftiniju i bolju zamjenu za istu radnju, baš kao što se dogodilo sa strojevima za aritmetiku. Međutim, to ne znači da će ljudski poslovi propasti kao što mnogi stručnjaci nagovještaju, nego će se, zbog vrijednosti ljudskih sposobnosti prosuđivanja, čak i povećati. (Sterne, 2017: 262)

Što se tiče implementacije umjetne inteligencije u svakodnevni život i marketing, ona je već prisutna te se ljudi susreću s njom svaki dan. „Ako ste ikad koristili Amazon ili Netflix, veliki su izgledi da ste već odavno upoznati s prijedlozima povezanih, tj. sličnih proizvoda. U nastojanju da poboljšaju korisničko iskustvo, mnoge tvrtke koriste umjetnu inteligenciju za praćenje navika i želja svojih korisnika kako bi pred njih stavile proizvode za koje vjeruju da će njihovi korisnici biti zainteresirani. To je nešto kao virtualni upsell baziran na softverskom programu.“ (Arbona, 2018: 5 načina kako umjetna inteligencija pozitivno utječe na digitalni marketing. Pristupljeno 11.3.2022.) Marketinški stručnjaci često spominju *RankBrain* algoritam koji je *Google* 2015. godine pokrenuo kao sustav “robotskog učenja koji pomoću

umjetne inteligencije odgovara na upite korisnika baš kao što bi to odgovorilo ljudsko biće. Na primjer, upitate li *Google* koliko Severina ima godina, on će vam k'o iz topa dati odgovor na postavljeno pitanje.“ (Arbona, 2018: 5 načina kako umjetna inteligencija pozitivno utječe na digitalni marketing. Pristupljeno 11.3.2022.) Nadalje, ovaj sustav, uz odgovor na traženo pitanje, također nudi i odgovore na niz sličnih pitanja na koja korisnici često traže odgovore ili ih često upisuju u tražilicu. Sve ove rezultate omogućuje umjetna inteligencija. Umjetna inteligencija koristi razne algoritme i zbog toga je primjenjiva i potrebna u marketingu, posebice digitalnom. Najčešće korišteni algoritmi u ovoj domeni su oni pomoću kojih “pametni program generira sadržaj s najboljom kombinacijom ključnih riječi koja će privući čitatelje i nagovoriti ih da učine ono što i želite (npr. otvore *newsletter*, pritisnu *like* na stranicu ili preuzmu e-book). Ovakav tip programa izvrstan je i u stvaranju *Subjecta* (naslova) za *Newsletter*, za sadržaj u *Facebook* oglasima, pa i za objave na društvenim medijima.” (Arbona, 2018) Danas se podaci mogu pronaći bilo gdje i preraditi u informacije, odnosno ‘*insightse*’³ koje tada digitalni marketing stručnjaci mogu koristiti za pametno donošenje marketinških odluka. Primjer su *Facebook Insights* u kojima se, između ostalog, može vidjeti tko lajka, točnije, stiće svidanje na objavama, odakle su osobe, što vole i kojeg su spola. Ti podaci također se mogu dobiti i putem *Google Analyticsa* i mnogih drugih sličnih programa. Ovakvi programi štede vrijeme poduzećima jer pametni strojevi i umjetna inteligencija mogu predvidjeti kolike su šanse da će netko temeljem uporabe upita na *Google* tražilici završiti na oglasu određene tvrtke koja ga je postavila. Može se zaključiti da već sada, ali i u budućnosti, neće biti potrebe za nagađanjima i testiranjima jer će to umjetna inteligencija raditi za tvrtke i pojedince koji se odluče za digitalne marketinške poteze i oglašavanje online. Bitan faktor utjecaja umjetne inteligencije na digitalni marketing jest i utjecaj umjetne inteligencije na oblikovanje ponašanja potrošača “i kako to utiče na osviještenost ili korisničko iskustvo s robnom markom? Kakva je uloga pretraživača i otkrivanja novih proizvoda, ako je glas glavna dostupna tačka na internetu? Kakvu ulogu imaju automatizirane pričalice roboti ili digitalni pomoćnici u tradicionalnom tržišnom lijevku i kako ćemo riješiti tu novu paradigmu? Kada se pojavi mogućnost za predviđanje potreba potrošača – od pomoći pri izboru ulaznica za kino, do odgovora na česta pitanja o proizvodima i uslugama – može nam pomoći umjetna inteligencija.” (Media Marketing 2017: Šta umjetna inteligencija znači za marketing? Pristupljeno 11.3.2022.)

³ insight (engl. = uvid, pronicavost), u psihologiji označuje nenadani uvid koji vodi rješenju nekog problema. (Rječnik.com: Značenje insight, Pristupljeno 11.3.2022.)

7. UPORABA I UTJECAJ UMJETNE INTELIGENCIJE NA POTROŠAČE U MARKETINGU

Svota koju kupci odvajaju za kupnju povećava se iz dana u dan i u to više nema sumnje. Strojno učenje jedan je od ključnih elemenata umjetne inteligencije koji omogućuje tvrtkama i marketinškim timovima da dekodiraju ogromnu akumulaciju podataka koja sužava informacije na način koji im pomaže identificirati ciljnu publiku, ono što klijenti traže, da naprave analizu trenda te zatim kreiraju tokove koji su usredotočeni na korisnike. Time se smanjuje utrošeno vrijeme i u konačnici se potencijalni klijenti pretvaraju u stalne potrošače ili konzumere. Osim što marketinški timovi mogu lakše identificirati svoju ciljanu publiku, također mogu izgraditi svoje marketinške strategije bazirane na ciljanoj publici. Marketinški timovi točno znaju kada treba upotrijebiti e-mail marketing, tj. mogu znati u koje vrijeme će korisnici najvjerojatnije otvoriti svoju e-poštu. Ovdje veliku ulogu igra i konkurencija. Naime, poduzeća i tvrtke sada moraju obraćati veću pozornost na ono što nude i kome to žele ponuditi. Primjerice, ako netko želi kao ciljnu skupinu žene i tinejdžerice te želi znati o njihovim interesima, može doći do podataka koristeći se umjetnom inteligencijom. Prediktivna personalizacija putem umjetne inteligencije pomogla je raznim brendovima da se pojave s personaliziranim korisničkim iskustvom. Danas potrošači ne moraju posebno izdvajati vrijeme za odlazak u trgovinu za nabavku određenih proizvoda. Uz takve dostupne prediktivne podatke, brendovi će doći do ideja koje će biti u mogućnosti podići korisničko iskustvo na veću razinu. To se može vidjeti kroz praćenje trendova koji su se pojavili, poput virtualne kupovine gdje se određeni proizvodi šalju do kupca, čak i prije kupovine, kako bi kupac mogao proizvod isprobati, a time brendovi pokušavaju 'natjerati' kupca da taj proizvod želi. Na taj način kupci osjećaju da je iskustvo ili trud uložen samo za njih. Personalizacija je ključ za pretvaranje potencijalnih klijenata u stvarne potrošače i konzumente. (Miler, 2021: How Artificial Intelligence Has Influenced Consumer Behavior. Pristupljeno 14.3.2022.)

Predviđa se kako će umjetna inteligencija najviše utjecati na iznose koje će potrošači odvajati za određene reklamirane i oglašavane proizvode, programe lojalnosti kupaca, promjene načina obavljanja kupovine i prilagodbu na online trgovinu, prilagodbu potrošača i stvaranje novih navika povezanih sa zvučnom tehnologijom te će, naravno, utjecati na povjerenje i produbiti odnose s potrošačima i konzumentima.

Počevši od iznosa koji će potrošači odvajati za proizvode i njihov rast, potpuno kognitivne web stranice drastično će utjecati na promjenu ponašanja i odabire pri kupnji. Već sada se može primijetiti povećanje prosječne potrošnje na web stranicama. Kognitivne web lokacije vode potrošače kroz pametno osmišljeni put, dopuštajući im da kupuju prije nego što im padne koncentracija ili umor koji može omesti kupnju. Ideja je da umjetna inteligencija koristi strojno učenje kako bi naučila o potrošaču i onome što želi, a zatim implementira pametnije puteve i smjernice na koje potrošač može pozitivno reagirati. (Szatyłowicz, 2019: 5 Ways Retail AI Will Influence Consumer Behavior. Pristupljeno 15.3.2022.)

Nadalje, odanost kupaca jedna je od najbitnijih stavki za svako poduzeće ili tvrtku. Istraživanja ukazuju na to da pridobivanje novoga kupca može proizvesti 25 puta više troškova, nego rad na zadržavanju već postojećeg kupca. Razne studije također ukazuju da bi se čak 49 % kupaca vratilo na online lokaciju da je na njoj bila prisutna umjetna inteligencija. U osnovi, umjetna inteligencija je u stanju koristiti strojno učenje za pridobivanje odanosti kupaca. Digitalni potrošači su iscrpljeni beskrajnim nizom neprikladnih proizvoda koji nisu u njihovoj sferi zanimanja. Ako bi uspjeli pronaći online rješenje koje im može preporučiti proizvode u kojima bi uživali, vjerojatnost je da će se i držati tog rješenja, a umjetna inteligencija ovu potražnju potrošača može lako zadovoljiti. Osim toga, umjetna inteligencija može ići i puno dalje kako bi se poboljšalo korisničko iskustvo. Primjerice, *Airbnb*ovo pretraživanje koje pokreće umjetna inteligencija obuhvaća velike količine podataka kako bi potrošač mogao dobiti ponudu s personaliziranim unosima. Korisnik će tako biti uparen s odgovarajućim domaćinima i oglasima kao i iskustvima i susjedstvima koja bi mogla olakšati i poboljšati boravak. Uz takvu uslugu, ne postoji razlog zašto bi potrošač kupnju i rezervaciju obavljao negdje drugdje kada mu zatreba pauza. (Szatyłowicz, 2019.)

Bitno je istaknuti kako se kupci već sada prilagođavaju na veću udobnost i naviku uporabe internetske trgovine te veće pogodnosti koje ona pruža. Prepoznavanje lica i otisaka prstiju potrošačima omogućuje brže naručivanje. Osim toga, omogućena je sigurnost pristupa vlastitim uređajima, kao i tehnologija detekcije glasa vođena umjetnom inteligencijom koja će vremenom omogućiti i bolje razgovore s digitalnim pomoćnicima kako bi riješili prepreke te pomogli potrošaču približiti proizvode koje on priželjkuje. Obzirom na mnoga vrata koja se uskoro mogu otvoriti, tvrtke trebaju uzeti zalet te biti u toku s trenutnim i nadolazećim trendovima u ovoj sferi.

Što se tiče nadolazećih zvukovnih tehnologija vezanih uz umjetnu inteligenciju, za primjer se može uzeti *PayPal* koji je već stvorio aplikaciju koja omogućava plaćanje glasovnim aktivacijama koje su vođene umjetnom inteligencijom. Tu se također može uvrstiti i tvrtka *Dominos Pizza* koja je lansirala 'vještinu' koja omogućuje kupcima da svojim glasom naruče krišku pizze. Ovakav pristup se pojavio jer su potrošači kroz svakodnevno pretraživanje došli do zaključka da glasovna pretraživanja bolje generiraju rezultate od tekstualnih. S jedne strane, glasovni upiti omogućuju intimniju komunikaciju između potrošača i brenda. Korisnici koji se svakodnevno koriste ovom vrstom pretraživanja ograničeni su na uređaje poput *Amazon Echoa* koji se koristi za obavljanje više zadataka. No, obzirom na to da sve više potrošača koristi glasovno pretraživanje, velika je vjerojatnost da će se povećati proizvodnja uređaja koji mogu zadovoljiti ovakve potrebe kupaca. Glasovna tehnologija raste i počinje zauzimati veliku ulogu u svakodnevnom životu te se zbog toga kupci sve radije oslanjaju na nju. Tvrtke, kao rezultat toga, moraju implementirati više glasovnih preporuka kako bi glasovno oglašavanje postalo lakše i proširenije. Ova vrsta tehnologije također će mijenjati način na koji potrošači obavljaju svoju kupnju online, u smislu da se više neće morati prebacivati s različitih kanala za kupnju, nego će im sve potrebno i ono što priželjkuju biti servirano u jednom sučelju kojem će se moći pristupiti jednostavnim korištenjem vlastitog glasa. Ovakva vrsta sučelja već postoji na *Amazonovoj Aleksi* te čini iskustvo kupovine prikladnijim ne samo za njih, nego i za kupce u budućnosti. (Szatyłowicz, 2019.)

Veliku ulogu u novim pristupima koje donosi umjetna inteligencija igra privatnost korisnika koja vjerojatno nikada nije bila važnija. Brendovi znaju da kupci trebaju povjeriti svoje informacije kako bi mogli obaviti kupnju i kako bi se oni kao brend mogli razvijati na mreži. Kao produkt ovih situacija, tvrtke su počele shvaćati transparentnost, poštenje i sigurnost vrlo ozbiljno dok grade veze s klijentima. Najlakši načini kojima brendovi pokušavaju izgraditi i steći povjerenje svojih potrošača jest nudeći velike količine vrijednosti (kuponi, bodovi) u zamjenu za detalje i informacije od svojih kupaca. U ovom procesu nastupa umjetna inteligencija, kao što se može vidjeti iz primjera *Googloveovog Nowa* i *Amazonove Alekse*. Kupci vjeruju proizvodima vođenim umjetnom inteligencijom jer personaliziraju iskustva i time grade povjerenje, a kada potrošač to okusi, rado će predati svoje osobne podatke. (Szatyłowicz, 2019.)

8. BUDUĆNOST UMJETNE INTELIGENCIJE U DIGITALNOM MARKETINGU

Budućnost nije u potpunosti predvidiva, no pojedini ishodi ipak se mogu očekivati. Što se tiče same primjene umjetne inteligencije, ona će unijeti promjene u svakodnevni život te će otvoriti nova vrata za marketinške trendove. Velika je vjerojatnost da će svaki elektronički proizvod imati mogućnost povezivanja s internetom i spajanja na sisteme umjetne inteligencije. Mogućnosti su ogromne – od satova, svjetiljki, tostera, kućanskih aparata sve do naočala, pa čak i majica ili tepiha. Veliki je problem za napredak tvrtki opasnost od rizika, točnije strah od promjene, tj. nečeg novog. Zato se napreci očekuju u novootvorenim tvrtkama koje vode mladi ljudi.

Umjetna inteligencija ima velik potencijal za promjenu načina obavljanja kupnje. Osim što pripomaže u razvoju online trgovine, mogu se vidjeti promjene i u tradicionalnom obliku kupovine. Zbog toga razni brendovi eksperimentiraju s novim mogućnostima koje umjetna inteligencija donosi, u svrhu poboljšanja iskustva kupovine. Kao primjer se može uzeti *TopShop*, britanski multinacionalni lanac odjeće, koji je koristio tehnologiju umjetne inteligencije kako bi stvorio virtualna stjecanja za svoju trgovinu u Moskvi. Kupci su u toj trgovini mogli provjeriti kako im, primjerice, haljina stoji jednostavno stojeći ispred ekrana i kamere. Umjetna inteligencija omogućila je kupcu da stane ispred velikog ekrana i vidi svoju virtualnu verziju te tako isprobava različite proizvode bez potrebe za odlaskom u prostoriju za presvlačenje i mjerenje. Uz *TopShop*, treba spomenuti i primjer trgovine *IKEA* koja podiže marketing umjetne inteligencije na višu stepenicu. *IKEA* pokreće aplikaciju temeljenu na AR-u (proširenoj stvarnosti)⁴ koja će omogućiti kupcima vizualizaciju *IKEA* proizvoda u vlastitom domu. Kupci će moći unijeti dimenzije svoje sobe te će nakon toga vidjeti proizvode različitog dizajna prikladne za prostor utemeljene na unesenim podacima. Kada kupac odabere željeni proizvod, moći će vidjeti kako će taj proizvod izgledati u njegovom domu kada ga se smjesti na željeno mjesto. Kupac može izravno naručiti proizvod iz aplikacije, što znači da, uz mogućnosti koje proširena stvarnost kupcima ovdje nudi, oni mogu i nesmetano obavljati kupovinu bez napuštanja udobnosti vlastitog doma. (Barker, 2021: The Future of AI in Digital Marketing: 2022 and Beyond. Pristupljeno 16.3.2022.)

⁴ „Proširena stvarnost (AR) moćan je alat za vizualizacije u realnom vremenu, koji može proširiti naš pogled stvarnog svijeta s računalno generiranim osjetilnim podražajima (zvuk, video, grafika, GPS podaci...). Proširena stvarnost tako uvodi komponente digitalnog unutar percepcije stvarnog svijeta.“ (Ditdot: Virtualna i proširena stvarnost, Pristupljeno 16.3.2022.)

Predviđa se da će, osim svega navedenoga, umjetna inteligencija uskoro u potpunosti preuzeti dizajniranje web stranica. Danas već postoje platforme, kao što je primjerice *The Grid*, koje koriste umjetnu inteligenciju kako bi dizajnirale web stranicu za korisnike na temelju korisničkih podataka i načina na koji oni stupaju u interakciju s njihovim sadržajem. Uz platformu *The Grid*, jedina briga koja preostaje vlasnicima poduzeća jest sadržaj web stranice. Za sve ostale attribute na stranici, od boja i blokova, brine se njihova dizajnerica umjetne inteligencije, *Molly*. *Molly* je baš kao *Siri* i *Alexa* te ljudi mogu razgovarati s njom i raspravljati o dizajnu svoje web stranice. Smatra se da će koristeći *The Grid* vlasnici web stranica brže završiti svoj dizajn. Uz *The Grid*, ima još nekoliko platformi za dizajn web stranica uz pomoć umjetne inteligencije – *FireDrop* i *Wix Artificial Design Intelligence (ADI)*. *FireDrop*ova dizajnerica umjetne inteligencije, poznatija kao *Sacha*, ima mogućnost pomoći vlasnicima web stranice pri izgradnji odredišnih stranica. Ona je programirana da prihvaća naredbe kako bi olakšala proces dizajniranja. *Wix Artificial Design Intelligence* omogućava dizajnerima web stranica da gledaju dizajnere umjetne inteligencije bez da ometaju njihovu trenutnu web stranicu. Namjera ove platforme je dati vlasnicima web sjedišta uvid u ono što je umjetna inteligencija sposobna učiniti. Ova platforma preuzima informacije o poslovanju vlasnika s interneta te, na temelju toga, dijeli informacije u odjeljke i pomoću toga dizajnira željene stranice. Trenutno su ovi graditelji web stranica uz pomoć umjetne inteligencije još uvijek u ranim stadijima, no očekuje se veliki napredak.

Marketing, osim prednosti koje donosi umjetna inteligencija, predviđa i velike nedostatke. Jedan od najviše pozicioniranih strahova na listi jest strah od toga da čovječanstvo korača u budućnost u kojoj će ljudi biti suvišni u poslovima koji se tiču digitalizacije. No naprotiv, stručnjaci predviđaju kako će umjetna inteligencija stvoriti više radnih mjesta nego što će ih uništiti. Ono što je neizbježno jest da će se određeni poslovi, ako ne i cijela radna atmosfera, u tvrtkama morati promijeniti. (Sterne, 2017: 308)

Prvi od izazova s kojima će se digitalni marketing uporabom umjetne inteligencije suočiti jest čovjek. Jučerašnji standardi i načini razmišljanja, kao i kontrolne liste, još uvijek previše utječu na marketing i time ga sputavaju. Strategije se emitiraju masama na svim mogućim kanalima. Razgovor s ljudima vodi se bez odvajanja vremena da se shvati tko su, što su, koga oni cijene i vole, koji su njihovi ciljevi i zašto donose određene odluke. Umjetna inteligencija pomaže trgovcima u razumijevanju modernih kupaca na načine koje do sad nisu koristili. Marketing s umjetnom inteligencijom kombinira inteligentnu tehnologiju s ljudskom

kreativnošću, željom za učenjem, razumijevanjem i interakcijom s potrošačima na individualnoj razini. (Alford, no date: AI marketing: What does the future hold? Pristupljeno 16.3.2022.)

9. ISTRAŽIVANJE I HIPOTEZE

Sukladno temi rada, provedena je anketa kako bi se testirale postavljene hipoteze. Provedeno je istraživanje koje se odnosi na svjesnost potrošača o umjetnoj inteligenciji. Teorijski dio pokriva sadržaje o umjetnoj inteligenciji i modernom marketingu te o utjecaju ova dva pojma na potrošače, a istraživački dio rada nastoji prikazati u kojoj su mjeri sudionici upoznati s pojmom umjetne inteligencije te njihovu svjesnost o tome koliko umjetna inteligencija utječe na njihove odluke pri kupovini. U idućim odlomcima navode se problem i cilj istraživanja, metodologija istraživanja, kao i grafički prikaz rezultata ankete. Interpretacija rezultata ankete provedena je uz pomoć deskriptivne statistike. Hipoteze koje su bile podvrgnute testiranju objašnjene su i razrađene putem ankete.

9.1. PROBLEM I CILJ ISTRAŽIVANJA

Problem istraživanja jest upoznatost i svjesnost potrošača o umjetnoj inteligenciji i o tome koliko ona utječe na njihove odluke pri kupovini. Ljudi jesu upoznati s ovom temom, no nisu u potpunosti svjesni koliko umjetna inteligencija analizira podatke i koliko je teško razlikovati informacije koje su produkt umjetne inteligencije od onih koje nisu. Anonimna anketa izrađena je putem *Google* obrasca kojem je moguće pristupiti putem e-maila. Prikupljeni su osnovni podaci o sudionicima te njihovi stavovi o utjecaju umjetne inteligencije na prikazivanje reklama koje ih okružuju, primjeni *chatbotova* na web stranicama i u njihovoj okolini, kao i preferencije prema online kupovini u usporedbi s tradicionalnom kupovinom.

9.2. METODOLOGIJA ISTRAŽIVANJA

Anketa je bila dostupna za ispitanike tijekom ožujka i travnja 2022. godine. Anketi je pristupilo 100 ispitanika, nakon čega je anketa zatvorena. Anketni je upitnik podijeljen putem društvenih mreža (*Facebook* i *Instagram*) te putem elektroničke pošte. Ova anonimna anketa trajala je svega pet minuta i sastojala se od ukupno 31 pitanja, od kojih je 27 vezano uz

dokazivanje hipoteza, a 4 pitanja odnosila su se na opće podatke ispitanika. Pitanja na ovom upitniku bila su sastavljena po principu Likertove skale. Njezine vrijednosti su od 1 do 5, gdje stupanj slaganja 1 podrazumijeva da se ispitanik uopće ne slaže, a stupanj 5 da se ispitanik u potpunosti slaže s navedenom tvrdnjom. Također, u ovoj anketi dodana je i vrijednost 0 za one koji nisu upoznati s pojmovima. Uzorak istraživanja sadržava ukupno 100 ispitanika te je to konačan broj ispitanika koji je obuhvaćen u nastavku rada.

9.3. HIPOTEZE

Tijekom istraživanja u fokusu su bile četiri hipoteze koje su se nastojale dokazati odgovorima ispitanih sudionika te je anketni upitnik, shodno tome, bio podijeljen u četiri dijela. Definiranjem i identifikacijom predmeta, cilja i svrhe istraživanja, postavljene su četiri glavne istraživačke hipoteze:

H1: Utjecaj umjetne inteligencije u oglašavanju putem određenih društvenih mreža, kao što je primjerice *YouTube*, postaje uočljiviji.

H2: Potrošači su svjesni češće primjene *chatbotova* i digitalnih asistenata na prodajnim portalima, stranicama, radnim mjestima i kućanstvima.


H3: Sve većim utjecajem umjetne inteligencije na proces potrošačevog donošenja odluke o kupovini, online kupovina postaje češća.

H4: Razlika između umjetno generiranih i stvarnih podataka teško se raspoznaje.

9.4. REZULTATI ISPITIVANJA

Prvi dio ankete odnosi se na opće podatke o ispitanicima. Prvo pitanje obuhvaća izjašnjavanje ispitanika o spolu. Od 100 ispitanika, njih 28, odnosno 28 % je muškog spola, dok je njih 72 ili 72 % ženskog spola. Dobiveni rezultati prikazani su na sljedećem grafikonu.


Spol
100 odgovora



Izvor: Google anketa, izrada autora.

Iduće pitanje odnosi se na dob ispitanika koji su sudjelovali u rješavanju anketnog upitnika. Anketa je bila proslijeđena s namjerom da u njoj sudjeluju samo punoljetni ispitanici. Najviše ispitanika je u dobi od 18 do 23 godine, čak 50 %, nakon čega slijedi broj ispitanika u starosti od 24 do 29 godina života (35 %). Nešto manje ispitanika imalo je između 30 i 35 godina (10 %), iza kojih slijede ispitanici od 36 do 41 godina (1 %) te oni od 47 do 55 godina (3 %), a samo 1 osoba (1 %) ima više od 55 godina. Prema podacima, anketi nisu pristupili ispitanici u dobi od 42 do 47 godina.

Dob
100 odgovora




Izvor: Google anketa, izrada autora.

Treće se pitanje odnosi na postignuti stupanj obrazovanja ispitanika. Prema dobivenim rezultatima, polovica ispitanika (50 %) ima završenu višu školu ili fakultet. Odmah nakon toga slijedi 40 % ispitanika sa završenom strukovnom školom ili gimnazijom te iza njih slijede

ispitanici sa završenim magisterijem ili doktoratom (9 %). Očekivano, najmanji broj ispitanika ima završenu samo osnovnu školu (1 %) te od pristupljenih niti jedna osoba nije bez ikakve školske spreme.


Obrazovanje
100 odgovora



Izvor: Google anketa, izrada autora.

Pitanje koje je također svrstano uz opća pitanja jest upoznatost ispitanika s pojmom umjetne inteligencije. Od 100 ispitanika samo se dvoje njih izjasnilo kako nije upoznato s pojmom, dok ostalih 98 % tvrdi da su upoznati sa značenjem pojma umjetne inteligencije. Pregledavanjem ankete, primijećeno je da osobe koje su negativno odgovorile na ovo pitanje spadaju u dobne skupine od 18 do 23 te od 24 do 29 godina te su obje ženskoga roda, što nije očekivano, obzirom da je mladež danas u toku s tehnologijom.


Upoznat/ta sam s pojmom umjetne inteligencije
100 odgovora



Izvor: Google anketa, izrada autora.

Posljednje pitanje u ovoj skupini odnosi se na razmišljanje ispitanika o poboljšanju svijeta putem umjetne inteligencije. Niti jedna osoba za ovo pitanje nije označila da nije upoznata s pojmom te je njih 3 (3 %) od 100 označilo da se uopće ne slažu s tvrdnjom. Nadalje,

8 (8 %) njih izjasnilo se kako se djelomično ne slažu s tvrdnjom, a 14 ispitanika je neutralnog mišljenja. Čak 57 (57 %) ispitanika djelomično se slažu s tezom, dok se njih 18 (18 %) u potpunosti slaže s tezom.



Izvor: Google anketa, izrada autora.

Iduća sekcija tvrdnji vezana je uz prvu hipotezu: Utjecaj umjetne inteligencije u oglašavanju putem određenih društvenih mreža, kao što je primjerice *YouTube*, postaje uočljiviji. Po tablici je vidljivo kako se s većinom tvrdnji najveći broj ispitanika slaže.

Najveći broj odgovora 4 i 5 na skali ima tvrdnja koja glasi: „Sve češće primjećujem reklame i oglase na raznim društvenim mrežama“, na koju je čak 75 % ispitanika označilo peticu na skali. Odmah iza nje slijedi tvrdnja: „Primjećujem da se oglasi i reklame koje viđam temelje na onome što sam do sada pretraživao/la“, za koju je 74 % ispitanika odgovorilo da se u potpunosti slaže. Ostale tvrdnje nisu imale toliko očite i sigurne odgovore na skali, no djelomično slaganje je prevladalo nad negativnim dijelom skale. Zanimljivo je kako se čak 44 % ispitanika izjasnilo da im se preporučeni video sadržaji ili serije na *YouTubeu* i *Netflixu*, koje se generiraju obzirom na prethodno pregledano, sviđaju te se djelomično slažu, a njih 13 % odgovorilo je da se u potpunosti slažu s tvrdnjom. Samo je 23 ispitanika odgovorilo s brojkom 1 (14 %) ili 2 (9 %) na skali.

Tablica 1: Hipoteza 1

TVRDNJA	Stupanj slaganja ispitanika s navedenim tvrdnjama					
	*0 Nisam upoznat/a s pojmom, 1 Uopće se ne slažem, 2 Djelomično se ne slažem, 3 Neutralnog sam mišljenja, 4 Djelomično se slažem, 5 U potpunosti se slažem					
	0	1	2	3	4	5
Umjetna inteligencija ima sposobnost generirati bolji i personalizirani sadržaj.	2	4	8	15	42	29
Sve češće primjećujem reklame i oglase na raznim društvenim mrežama.	1	2	2	4	16	75
Primjećujem da se oglasi i reklame koje vidam temelje na onome što sam do sada pretraživao/la.	0	0	2	7	17	74
Češće kliknem ili provjerim preporučene reklame online za razliku od prije.	5	18	16	20	25	16
Sviđaju mi se preporučeni video sadržaji ili serije na <i>YouTubeu</i> i <i>Netflixu</i> koje se generiraju s obzirom na ono što sam prethodno pregledavao/la.	2	14	9	18	44	13

Izvor: Podaci iz Google ankete, izrada autora.

Tablica 2 obuhvaća grupu odgovora vezanih uz drugu hipotezu: Potrošači su svjesni češće primjene *chatbotova* i digitalnih asistenata na prodajnim portalima, stranicama, radnim mjestima i kućanstvima. Najveći broj ispitanika (63 %) odabrao je najveći stupanj neslaganja pri tvrdnji: „Osobno se koristim glasovnim/digitalnim asistentima (*Alexa, Cortana*..)“, kao i za tvrdnju: „Moji kolege/prijatelji/bližnji koriste digitalne asistente“, gdje je njih 40 % odgovorilo s jedinicom na skali. Prema tablici, za daljnje su tvrdnje vidljiva podjednaka i neutralna mišljenja na skali, osim za tvrdnju koja potvrđuje hipotezu, a koja glasi:

„Primjećujem sve češću pojavu *chatbotova* na internet stranicama“, gdje je 31 % ispitanika odgovorilo da se u potpunosti slažu s tvrdnjom. Čak 27 % ispitanika odgovorilo je da se djelomično slažu. Navedeno čini više od 50 % potvrdnih odgovora na postavljenu hipotezu.

Tablica 2: Hipoteza 2

TVRDNJA	Stupanj slaganja ispitanika s navedenim tvrdnjama					
	*0 Nisam upoznat/a s pojmom, 1 Uopće se ne slažem, 2 Djelomično se ne slažem, 3 Neutralnog sam mišljenja, 4 Djelomično se slažem, 5 U potpunosti se slažem					
	0	1	2	3	4	5
Osobno se koristim glasovnim/digitalnim asistentima (<i>Alexa, Cortana...</i>).	13	63	5	6	8	5
Moji kolege/prijatelji/bližnji koriste digitalne asistente.	16	40	13	11	17	3
<i>Chatbotovi</i> su digitalni asistenti koji su važni u tehnologiji umjetne inteligencije.	16	13	13	20	28	10
<i>Chatbotovi</i> (digitalni asistenti) utječu na poboljšanje kupnje.	14	16	13	23	25	9
Primjećujem sve češću pojavu <i>chatbotova</i> na internet stranicama.	13	11	8	10	27	31

Izvor: Podaci iz Google ankete, izrada autora.

Tablica 3 prikazuje sedam tvrdnji koje se odnose na hipotezu broj tri koja nastoji dokazati da online kupovina postaje češća sve većim utjecajem umjetne inteligencije na proces potrošačeva donošenja odluke o kupovini. Naime, na temelju ove tablice vidljivo je u kojoj se mjeri ispitanici slažu s navedenim tvrdnjama. Niti jedan kraj skale nije odnio 100 % glasova.

Najveći broj sudionika (69 %) složio se s tvrdnjom da se novi marketing trendovi trude potaknuti kupce na kupnju. Niti jedna osoba nije označila da se u potpunosti ne slaže s ovom tvrdnjom. Čak 35 % ispitanika odgovorilo je kako se djelomično slažu da online oglašavanje putem društvenih mreža utječe na njihovu kupnju, dok se njih 11 % u potpunosti slaže, a 20 % ispitanika neutralnog je mišljenja. Veliki dio ispitanika složio se ili djelomično (40 %) ili u potpunosti (42 %) s tvrdnjom da online oblik kupovine sve više zamjenjuje tradicionalnu kupovinu. Više od 50 % ispitanika označilo je kako se često koriste mobilnim aplikacijama za kupovinu i narudžbe. Što se tiče tvrdnje: „Radije obavljam sve što mogu iz udobnosti svojega doma“, može se primijetiti da je skoro 50 % ispitanika označilo četvorku (20 %) ili peticu (29 %) na skali, no velik broj njih (21 %) ostao je neutralnog mišljenja. Također, velik broj neutralnih odgovora bio je i na tvrdnji: „Preferiram online kupovinu naspram tradicionalne kupovine“, gdje je 26 ispitanika označilo da su neutralnog mišljenja, dok je ostatak manje-više ravnomjerno raspoređen po skali. S posljednjom tvrdnjom koja glasi: „Smatram da je online kupovina brža, lakša i da se online kupovinom uštedi više vremena“, 34 % ispitanika u potpunosti se složilo, a njih 30 % djelomično se složilo.

Tablica 3: Hipoteza 3

TVRDNJA	Stupanj slaganja ispitanika s navedenim tvrdnjama					
	0	1	2	3	4	5
Novi marketing trendovi trude se potaknuti kupce na kupnju.	1	0	5	3	22	69
Oglašavanja na društvenim mrežama utječu na moju odluku o kupnji.	2	17	15	20	35	11
Tradicionalni oblik kupovine sve se više zamjenjuje online kupovinom.	0	2	7	9	40	42
Često se koristim mobilnim aplikacijama za kupovinu i narudžbe.	1	14	7	11	28	39
Radije obavljam sve što mogu iz udobnosti svoga doma.	1	16	13	21	20	29
Preferiram online kupovinu naspram tradicionalne kupovine.	2	22	13	26	19	18
Smatram da je online kupovina brža, lakša i da se online kupovinom uštedi više vremena.	2	9	12	13	30	34

Izvor: Podaci iz Google ankete, izrada autora.

Posljednja tablica odnosi se na hipotezu: „Razlika između umjetno generiranih i stvarnih podataka teško se raspoznaje.“ Ispitivanje ove hipoteze provedeno je upotrebom umjetno generiranih slika u usporedbi sa slikama koje su produkt ljudske prirode. Na tablici su priloženi odgovori sudionika, kao i točni odgovori. Prva slika bila je očita te je 67 % ispitanika odgovorilo točno, označavajući odgovor „T“. Za sliku 2, njih 82 % odgovorilo je točno, označavajući da slika nije produkt umjetne inteligencije. Nadalje, slika 3 podijelila je sudionike te je 51 % njih odgovorilo da je slika produkt umjetne inteligencije, što je točan odgovor, no razlika između točnih i netočnih odgovora je samo 1 %. Za sliku broj 4, 80 % ispitanika odgovorilo je točno, tj. da slika nije produkt umjetne inteligencije, dok je za sliku 5 njih 71 % odgovorilo pogrešno, odabirući da je slika produkt umjetne inteligencije. Slika 6 također je podijelila sudionike jer je 55 % njih odgovorilo netočno, a 45 % njih točno. Posljednja slika je prevarila ispitanike te je njih 67 % odgovorilo netočno, smatrajući da slika nije produkt umjetne inteligencije.

Tablica 4: Hipoteza 4

TVRDNJA		Smatrate li da je slika produkt umjetne inteligencije?	
		T (Slika je produkt umjetne inteligencije)	N (Slika nije produkt umjetne inteligencije)
Slika 1.	Odg: T	67	33
Slika 2.	Odg: N	18	82
Slika 3.	Odg: T	51	49
Slika 4.	Odg: N	20	80
Slika 5.	Odg: N	71	29
Slika 6.	Odg: N	55	45
Slika 7.	Odg: T	33	67

Izvor: Podaci iz Google ankete, izrada autora.

10. RASPRAVA

Rezultati anketnog upitnika provedenog na uzorku od 100 ispitanika omogućili su usporedbu te prikaze realnog stanja poznavanja pojma umjetne inteligencije, kao i njezin utjecaj na ispitanike te na njihove kupovne navike. Anketna pitanja sastojala su se od višestrukih izbora koji su bazirani na Likertovoj skali te točno/netočno, odnosno da/ne odgovora. Analizom ankete i odgovora moguće je doći do konkretnog stajališta potrošača i njihovog poznavanja pojma umjetne inteligencije.

Poznato je da je u današnje vrijeme online marketing postao vrlo popularan. Ljudi vrlo lako primjećuju oglase koji iskaču po društvenim mrežama, što je vidljivo u tablici broj 1, gdje više od 90 % ispitanika označava da se djelomično ili u potpunosti slažu s tvrdnjom: „Sve češće primjećujem reklame i oglase na raznim društvenim mrežama“, čime se potvrđuje hipoteza broj 1: „Uticaj umjetne inteligencije u oglašavanju putem određenih društvenih mreža, kao što je primjerice *YouTube*, postaje uočljiviji“. Također, više od 90 % sudionika primjećuje da se reklame temelje na onome što su prethodno pretraživali, a prijedlozi temeljeni na prijašnjim pretragama su algoritmi koji su najčešće produkt velikih podataka i analize koja je napravljena putem umjetne inteligencije.

Kako se online marketing popularizira, tako dolazi vrijeme *chatbotova* i digitalnih asistenata. Naime, pregledom kroz tablicu 2, može se primijetiti da *chatbotovi* nisu toliko prošireni u Hrvatskoj, budući da je više od 50 % sudionika odgovorilo kako se niti oni sami, a niti njihovi kolege/bližnji ne služe digitalnim asistentima. Ispitanici koji obavljaju kupovinu online primijetili su njihovu sve češću pojavnost, što se može iščitati iz tablice 2, gdje je više od 58 % ispitanika odgovorilo da se djelomično ili potpuno slažu s tvrdnjom: „Primjećujem sve češću pojavu *chatbotova* na internet stranicama“, time djelomično potvrđujući hipotezu 2: „Potrošači su svjesni češće primjene *chatbotova* i digitalnih asistenata na prodajnim portalima, stranicama, radnim mjestima i kućanstvima“.

Obzirom na češću primjenu online oglašavanja te na situaciju u svijetu s posljedicama koje je donjela pandemija, online kupovina postala je svakodnevica. Iz tablice je vidljivo kako se velika većina ispitanika, preciznije njih više od 80 %, u potpunosti ili djelomično slaže s tvrdnjom da online kupovina zamjenjuje tradicionalnu. Vidljivo je i da se preko 60 % njih

koristi mobitelom za kreiranje narudžbi online, potvrđujući time hipotezu da online kupovina postaje češća sa sve većim utjecajem umjetne inteligencije na proces potrošačevog donošenja odluke o kupovini. Umjetna inteligencija upotrebljava se kako bi generirala personalizirani sadržaj te kako bi lakše razvrstala podatke vezane uz korisnika, a koji utječu na reklame i ono što se korisniku preporučuje, što iznimno dobro prolazi kod korisnika koji većinu svojega vremena provode na mobilnim uređajima te koji pri tome preferiraju online kupovinu putem istog.

Uzbudljivo je razmišljati o budućnosti i onome što će sve umjetna inteligencija napraviti za čovječanstvo. Ljudi nisu svjesni koliko je stvari umjetno generirano – reklame, plakati, određeni internetski live chatovi, telefonski razgovori i ostalo. Iz tablice 4 mogu se očitati podaci o tome koliko ispitanici raspoznaju razliku između umjetno i prirodno generiranih podataka, gdje je vidljivo da ispitanici nisu u potpunosti sigurni što je produkt umjetne inteligencije, a što ne. Prve dvije slike iz tablice bile su očite te su služile kao uvod sudionika u princip ispitivanja. Nadalje, kod postavljanja manje očitih slika, glasovi su bili podijeljeni na skoro 50 %, čime je dokazana hipoteza: „Razlika između umjetno generiranih i stvarnih podataka teško se raspoznaje“.

11. ZAKLJUČAK

Umjetna inteligencija i njezin pojam počeo se razvijati još u ranim 50-im godinama 20. stoljeća, a svoju pravu uporabljivost pokazuje upravo sada. Digitalna revolucija i pojava interneta uvelike je promijenila svakodnevni život i donijela raznolike inovacije koje su u svom brzom razvoju morale biti popraćene strojevima i algoritmima. Budući da čovjek nije u mogućnosti prihvatiti tolike informacije u kratkom periodu, predviđa se kako će razvoj računala i strojeva nadmašiti postojeću ljudsku inteligenciju te da će jednoga dana biti u mogućnosti imati ljudske osjećaje. Obzirom na ovakav brzi razvoj i potrebu za umjetnom inteligencijom, ona je sada pristupačnija tvrtkama, što je čini vrijednim alatom za trgovce i stručnjake u digitalnom marketingu.

Neosporno je da umjetna inteligencija ima velik utjecaj na kupovne odluke potrošača, počevši od pomoći pri pružanju relevantnih preporuka i pravovremene korisničke usluge. Može se reći da se danas pojavila nova vrsta potrošača – ona koja je brza i informirana s velikim očekivanjima. Danas potrošači očekuju da će dobiti vrijednost robe i prije nego što ju kupe. Oni žele osjetiti da je brendu stalo do njih i njihovih potreba, žele da brend zna što potrošači žele i prije nego što se odluče na kupnju, potrebni su im prijedlozi, savjeti i odgovori. Ove potrebe neće nestati, nego će se vremenom povećavati te je zbog toga umjetna inteligencija jedini način na koji tvrtke mogu držati korak sa sve većom potražnjom i očekivanjima kupaca. Donošenje odluka o kupovini i proces koji je potreban da bi se odluka donijela puno je kompleksniji nego što se inače misli te na njega utječu brojni čimbenici, od vanjskih do unutarnjih. Iz tog razloga, proces donošenja odluka o kupovini specifičan je za svakog pojedinca, kao i njihove kupovne navike te će na tome području umjetna inteligencija i mogućnost personalizacije koju ona pruža imati glavne uloge.

Nakon anketiranja s ciljem pisanja ovoga rada, mogu se vidjeti rezultati koji ukazuju na utjecaj umjetne inteligencije pri kupovnim navikama ispitanih. Anketiranje je bilo podijeljeno u četiri sekcije od kojih je svaka zastupala jednu hipotezu. Sve su hipoteze djelomično ili u potpunosti potvrđene, a posebno hipoteza 1: “Utjecaj umjetne inteligencije u oglašavanju putem određenih društvenih mreža, kao što je primjerice *YouTube*, postaje uočljiviji” i hipoteza 3: “Sa sve većim utjecajem umjetne inteligencije na proces potrošačevog donošenja odluke o kupovini, online kupovina postaje češća.” Sve u svemu, dokazano je kako je utjecaj umjetne inteligencije sve veći te da ispitanici nisu u mogućnosti potpuno razlikovati

umjetno generirane podatke od stvarnih, što će s napretkom digitalizacije i umjetne inteligencije biti sve teže za detektirati. Istraživanje je imalo svojih ograničenja, kao što je primjerice mali uzorak ljudi usmjeren na ljude iz Republike Hrvatske, osobito na područje Slavonije i Baranje. Osim toga, anketni upitnik nije sadržavao pitanja o financijskom stanju ispitanika, što može utjecati na ishod jer nismo sigurni mogu li osobe odvojiti određena novčana sredstva za uređaje koji koriste umjetnu inteligenciju i žele li to uopće. Također, bitno je napomenuti da je u istraživanju sudjelovao mali broj ispitanika muškog spola, odnosno samo 28 % te je preporučljivo uključiti veći broj ispitanika muškoga spola u buduća istraživanja. Nadalje, istraživanju je pristupio velik broj ispitanika mlađih od 30 godina te se preporuča u buduća istraživanja uključiti veći broj starijih ispitanika s cjelokupnog područja Republike Hrvatske. Ovo istraživanje može poslužiti kao smjernica za daljnja istraživanja te bi bilo zanimljivo usporediti trenutne podatke s podacima za nekoliko godina, obzirom da u Hrvatskoj umjetna inteligencija i digitalni asistenti trenutno nisu zastupljeni u velikoj mjeri.

12. LITERATURA

Alford, J., no date: AI marketing: What does the future hold? Pristupljeno 16.3.2022. URL: https://www.sas.com/en_us/insights/articles/marketing/ai-marketing-what-does-the-future-hold.html

Anderson, J., Rainie, L. (2018.) Artificial Intelligence and the Future of Humans. Pristupljeno 18.2.2022. URL: <https://www.pewresearch.org/internet/2018/12/10/artificial-intelligence-and-the-future-of-humans/>

Anonymous (2022.) Marketinško značenje (Što je to, pojam i definicija) – Izrazi. Pristupljeno 1.3.2022. URL: <https://hr.encyclopedia-titanica.com/significado-de-marketing>

Anonymous, no date: E-mail marketing. Pristupljeno 7.3.2022. URL: <https://www.onlineoglašavanje.com/e-mail-marketing/>

Anonymous, no date: Što je Chatbot: Proces dizajniranja i njegova arhitektura. Pristupljeno 10.3.2022. URL: <https://hr.jf-parede.pt/what-is-chatbot-design-process-its-architecture>

Arbona, (2018.) 5 načina kako umjetna inteligencija pozitivno utječe na digitalni marketing. Pristupljeno 11.3.2022. URL: <https://www.arbona.hr/blog/online-digitalni-marketing/5-nacina-kako-umjetna-inteligencija-pozitivno-utjece-na-digitalni-marketing/709>

Burns, E., Laskowski, N., Tucci, L. (2022.) What is artificial intelligence (AI)? Pristupljeno 18.2.2022. URL: <https://www.techtarget.com/searchenterpriseai/definition/AI-Artificial-Intelligence>

Barker, S. (2021.) The Future of AI in Digital Marketing: 2022 and Beyond. Pristupljeno 16.3.2022. URL: <https://shanebarker.com/blog/ai-digital-marketing/>

Coperland, B. J., Artificial intelligence. Pristupljeno 18.2.2022. URL: <https://www.britannica.com/technology/artificial-intelligence>

Čmarec, J. (2019.) E-mail marketing kao element promotivnog spleta internetskog marketinga. Varaždin: Sveučilište u Zagrebu, Fakultet organizacije i informatike. Pristupljeno 7.3.2022. URL:
<https://repozitorij.foi.unizg.hr/islandora/object/foi%3A5675/datastream/PDF/view>

Ditdot: Virtualna i proširena stvarnost. Pristupljeno 16.3.2022. URL:
<https://www.ditdot.hr/usluge/virtualna-i-prosirena-stvarnost>

Golob, M. (2016.) Mobilni marketing kao sastavni dio integrirane marketinške komunikacije, Zbornik Veleučilišta u Rijeci, Vol. 4 No. 1, 147-158. Pristupljeno 7.3.2022. URL: <https://hrcak.srce.hr/160239>

Grundler, D. (2001.) Evolucijski algoritmi (I) Pobude i načela. Automatika: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije, 42(1-2), 13-22. Pristupljeno 28.2.2022. URL: <https://hrcak.srce.hr/file/8743>

Hr-Education-wiki.com, no date: Inteligentni agenti. Pristupljeno 28.2.2022. URL:
<https://hr.education-wiki.com/2391039-intelligent-agents>

Hrvatska enciklopedija: Bitcoin. Pristupljeno 22.2.2022. URL:
<https://www.enciklopedija.hr/natuknica.aspx?id=70775>

Hrvatska enciklopedija: Ekspertni sustavi. Pristupljeno 22.2.2022. URL:
<https://www.enciklopedija.hr/natuknica.aspx?id=17426>

Hrvatska enciklopedija: Heuristika. Pristupljeno 18.2.2022. URL:
<https://www.enciklopedija.hr/natuknica.aspx?id=25317>

Hrvatska enciklopedija: Marketing. Pristupljeno 1.3.2022. URL:
<https://www.enciklopedija.hr/Natuknica.aspx?ID=38988>

Hrvatska enciklopedija: neuronska mreža. Pristupljeno 22.2.2022. URL:
<https://www.enciklopedija.hr/natuknica.aspx?ID=43562>

Hrvatska enciklopedija: Umjetna inteligencija. Pristupljeno 18.2.2022. URL:
<https://www.enciklopedija.hr/natuknica.aspx?ID=63150>

K. Dwivedi, Y. et al. (2021.) Setting the future of digital and social media marketing research: Perspectives and research propositions, International Journal of Information Management Volume 59, 102168. Pristupljeno 9.3.2022. URL:
<https://www.sciencedirect.com/science/article/pii/S0268401220308082>

Lewis, T. (2014.) A Brief History of Artificial intelligence. Pristupljeno 18.2.2022. URL:
<https://www.livescience.com/49007-history-of-artificial-intelligence.html>

Markething (2020.) Što su influenceri i što sve trebate znati o njima. Pristupljeno 9.3.2022.
URL: <https://www.markething.hr/sto-su-influenceri-i-sto-sve-trebate-znati-o-njima/>

Marketing Fanciee (2018.): Mobilni marketing: definicija i značaj u digitalnom poslovanju. Pristupljen 7.3.2022. URL: <https://marketingfancier.com/mobilni-marketing-definicija-i-znacaj/>

Media Marketing (2017.) Šta umjetna inteligencija znači za marketing? Pristupljeno 11.3.2022. URL: <https://www.media-marketing.com/vijesti/sta-umjetna-inteligencija-znaci-za-marketing/>

Miler, K. (2021.) How Artificial Intelligence Has Influenced Consumer Behavior. Pristupljeno 14.3.2022. URL: <https://www.datasciencecentral.com/how-artificial-intelligence-has-influenced-consumer-behavior/>

N. Lemon, K. (2016.) The Art of Creating Attractive Consumer Experiences at the Right Time: Skills Marketers Will Need to Survive and Thrive. Pristupljeno 8.3.2022. URL:
<https://www.nim.org/en/publications/gfk-marketing-intelligence-review/all-issues/marketing-and-data-science/art-creating-attractive-consumer-experiences-right-time-skills-marketers-will-need>

Oracle, no date: What Is a Digital Assistant? Pristupljeno: 9.3.2022. URL:
<https://www.oracle.com/chatbots/what-is-a-digital-assistant/#:~:text=A%20digital%20assistant%2C%20also%20known,it%2C%20typically%20over%20the%20internet>

Oreški, D. (2016.) Što je digitalni marketing. Pristupljeno 18.2.2022. URL:
<https://ecommerce.hr/upoznajte-se-s-digitalnim-marketingom/>

PCCHIP (2018.) Što je to "machine learning" ili strojno učenje? Pristupljeno 22.2.2022.
URL: <https://pcchip.hr/helpdesk/sto-je-to-machine-learning-ili-strojno-ucenje/>

Rječnik.com: Značenje insight. Pristupljeno 11.3.2022. URL: <https://www.xn--rjenik-k2a.com/insight>

Social Media Marketing, lumen, no date: Introduction to Social Media and Digital Marketing. Pristupljeno 9.3.2022. URL: <https://courses.lumenlearning.com/boundless-marketing/chapter/introduction-to-social-media-and-digital-marketing/>

Sterne, J. (2017.) Artificial Intelligence for Marketing. Rixing Media

Szatyłowicz, K. (2019.) 5 Ways Retail AI Will Influence Consumer Behavior. Pristupljeno 15.3.2022. URL: <https://blog.crobox.com/article/ai-consumer-behavior>

Vaishali, T., no date : Vodič za velike podatke za početnike | Što su veliki podaci? Pristupljeno 28.2.2022. URL: <https://hr.myservername.com/big-data-tutorial-beginners-what-is-big-data>

Warwick, K. (2012.) Artificial intelligence: the basics. Milton Park, Abingdon: Routledge.