

Poslovna primjena generativne umjetne inteligencije prirodnog jezika na primjeru ChatGPT-a

Leko, Domagoj

Master's thesis / Diplomski rad

2024

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:148:516536>

Rights / Prava: [Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0](#)

Download date / Datum preuzimanja: **2024-11-09**



Repository / Repozitorij:

[REPEFZG - Digital Repository - Faculty of Economics & Business Zagreb](#)



Sveučilište u Zagrebu

Ekonomski fakultet

Integrirani preddiplomski i diplomski sveučilišni studij

Poslovna ekonomija – smjer Menadžerska informatika

**POSLOVNA PRIMJENA GENERATIVNE UMJETNE
INTELIGENCIJE PRIRODNOG JEZIKA NA PRIMJERU
CHATGPT-a**

Diplomski rad

Domagoj Leko

Zagreb, rujan 2024.

Sveučilište u Zagrebu

Ekonomski fakultet

Integrirani preddiplomski i diplomski sveučilišni studij

Poslovna ekonomija – smjer Menadžerska informatika

**POSLOVNA PRIMJENA GENERATIVNE UMJETNE
INTELIGENCIJE PRIRODNOG JEZIKA NA PRIMJERU
CHATGPT-A**

**BUSINESS APPLICATION OF GENERATIVE ARTIFICIAL
INTELLIGENCE OF NATURAL LANGUAGE ON THE
EXAMPLE OF CHATGPT**

Diplomski rad

Student: Domagoj Leko

JMBAG: 0067555398

Mentor: Prof. dr. sc. Mirjana Pejić Bach


Zagreb, rujan 2024.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Vlastoručni potpis studenta: 

U Zagrebu, 20. rujna 2024.

STATEMENT ON THE ACADEMIC INTEGRITY

I hereby declare and confirm by my signature that the final thesis is the sole result of my own work based on my research and relies on the published literature, as shown in the listed notes and bibliography.

I declare that no part of thesis has been written in an unauthorized manner, i.e., it is not transcribed from the non-cited work, and that no part of the thesis infringes any of the copyrights.

I also declare that no part of the thesis has been used for any other work in any other higher education, scientific or educational institution.

Personal signature of the student: 

In Zagreb, September 20th, 2024

Sažetak:

Umjetna inteligencija je u posljednjih nekoliko godina predmet velikog broja rasprava, analiza i istraživanja. Primarno zbog svoje disruptivne prirode i pozitivnog utjecaja na čovjekov dosadašnji tijek razvoja i način funkcioniranja, ali i zbog straha, neizvjesnosti te rizika koje donosi.

Umjetna inteligencija u javnom prostoru na značaju dobiva pojavom ChatGPT aplikacije koja se temelji na GPT modelu, velikom jezičnom modelu koji u svega nekoliko dana stječe globalnu popularnost i rekordni broj novih korisnika, odražavajući tako vrhunac tehnološkog razvoja, ali i entuzijazam zbog velikog potencijala i utjecaja na budućnost.

Iako je sama aplikacija namijenjena i korištenju u privatne svrhe, njen ukupni potencijal jasan je tek prilikom analize primjene u poslovanju poduzeća. Poduzeća u svrhu ostvarivanja i zadržavanja konkurentnosti kontinuirano teže optimizaciji poslovanja. ChatGPT i njegova integracija u poslovanje predstavljaju važan korak u digitalnoj transformaciji i stvaranju efikasnijeg poslovnog okruženja.

Ključne riječi: umjetna inteligencija, veliki jezični modeli, poslovni procesi, ChatGPT

Summary:

Artificial intelligence has been the subject of a large number of discussions, analyzes and researches in the last few years. Primarily because of its disruptive nature and positive impact on man's current course of development and way of functioning, but also because of the fear, uncertainty and risks it brings.

Artificial intelligence in the public space is gaining importance with the appearance of the ChatGPT application, which is based on the GPT model, a large language model that in just a few days is gaining global popularity and a record number of new users, thus reflecting the pinnacle of technological development, but also enthusiasm due to its great potential and impact on future.

Although the application itself is also intended for use for private purposes, its overall potential is only clear when analyzing its application in the company's operations. In order to achieve and maintain competitiveness, companies continuously strive to optimize their operations. ChatGPT and its integration into business represent an important step in digital transformation and the creation of a more efficient business environment.

Keywords: artificial intelligence, large language models, business processes, ChatGPT

Sadržaj

1. UVOD	1
1.1. Predmet i cilj rada	2
1.2. Izvori podataka i metode prikupljanja	2
1.3. Sadržaj i struktura rada	3
2. TEORIJSKA OSNOVA ZA OBRADU PRIRODNOG JEZIKA	4
2.1. Osnovni koncepti i izazovi u obradi prirodnog jezika (NLP)	13
2.1.1. Osnovni elementi jezika i njihova obrada u NLP	14
2.1.2. Izazovi u obradi prirodnog jezika	16
2.1.3. Etička pitanja i odgovornost u razvoju i primjeni obrade prirodnog jezika	17
2.2. Metode i modeli obrade prirodnog jezika	20
2.2.1. Metode obrade prirodnog jezika	20
2.2.2. Modeli obrade prirodnog jezika	22
2.2.3. Važnost kvalitetnih izvora podataka u obradi prirodnog jezika	25
2.3. Vrste pristupa strojnom učenju u obradi prirodnog jezika (NLP)	26
2.3.1. Supervizirano učenje u obradi prirodnog jezika	27
2.3.2. Nesupervizirano i polusupervizirano učenje u obradi prirodnog jezika	28
2.3.3. Preostali oblici učenja u obradi prirodnog jezika	29
3. CHATGPT MODEL	31
3.1. Osnovni koncepti, arhitektura i način funkcioniranja ChatGPT-a	32
3.2. Povijesni razvoj ChatGPT modela	37
3.3. Usporedba ChatGPT-a s drugim modelima za obradu prirodnog jezika	41
4. POSLOVNA PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE NA PRIMJERU CHATGPT-A	45
4.1. Utjecaj te prednosti i nedostaci implementacije ChatGPT-a u poslovanju	45
4.2. Primjeri područja podložnih automatizaciji poslovanja pomoću ChatGPT	51
4.3. Budućnost te izazovi i doprinos ChatGPT-a razvoju umjetne inteligencije	56
5. ZAKLJUČAK	59
LITERATURA	60
POPIS SLIKA	67
POPIS GRAFIKONA	67
POPIS TABLICA	67
ŽIVOTOPIS	68

1. UVOD

Civilizacija od samih početaka i prvih dokaza o nastanku ljudskih zajednica teži kontinuiranom razvoju svakodnevnih aktivnosti i procesa. Čovjek kao svjesno biće intuitivno teži biti bolji, produktivniji, optimizirati uložene resurse (rad, kapital, zemlju), a sve s krajnjim ciljem podizanja vlastitog životnog standarda, olakšavanja svoje svakodnevice i povećanja vlastitih proizvodnih kapaciteta.

Čovjekov razvoj svoje prve eksponencijalne korake pronalazi u otkriću parnog stroja u drugoj polovici 18. stoljeća. Upravo se u tom razdoblju po prvi puta unutar akademske zajednice počinje spominjati koncept tehnologije (Beckmann, 1787) kao skupa znanja koji povezuje tehniku, ekonomske pojave i društvo u cjelini. Svaka buduća tehnološka inovacija doprinijela je još većoj razini društvenog blagostanja. Tehnološki razvoj doveo je danas čovječanstvo na veliku prekretnicu.

Skup svih do danas prikupljenih podataka i razvijenih tehnologija čovjeku je omogućio promišljanje o kreiranju velikih jezičnih modela koristeći umjetnu inteligenciju koji omogućuju lakše i kvalitetnije prikupljanje, ali i strukturiranje i generiranje podataka. Ovi modeli svoje kapacitete temelje na velikom znanju i bazama podataka te tehnologiji kreiranima od samih ljudi. Pritom je važno naglasiti važnost kvalitete, ali i kvantitete podataka. U svijetu koji teži potpunoj digitalizaciji, podaci se zasigurno mogu smatrati izuzetno važnim pa i ključnim resursom zbog čega se proces digitizacije provodi sve češće i brže.

Nadalje, nameće se pitanje njihove ograničenosti i postoji li ona uopće. Postoji li mogućnost da podaci kao resurs ruše jednu od temeljnih ekonomskih pretpostavki o ograničenosti resursa? Uz navedeno, postavlja se i pitanje uloge umjetne inteligencije i velikih modela u čovjekovoj budućnosti. Kroz prošlost se pokazalo kako svaka tehnologija unaprijedi i proširi područja djelovanja čovjeka te, iako uz inicijalni strah od zamjenjivanja čovjeka tehnologijom, tehnologija u konačnici čovjeku isključivo služi kao produljena ruka i ispomoć u kreiranju jednostavnije budućnosti.

Sukladno navedenom, nameće se pitanje može li upravo današnji stupanj razvoja umjetne inteligencije biti onaj stadij u kojemu sama tehnologija zamjenjuje ulogu čovjeka i umanjuje njegovu važnost u razvoju budućih civilizacijskih i ekonomskih procesa. Generativna umjetna inteligencija samo je jedan od njezinih oblika i svojevrsna infrastruktura budućeg razvoja ove tehnologije. Sve navedeno dovodi do spoznaje važnosti generativne umjetne inteligencije i ChatGPT-a kao pionira najvišeg spoznatog stupnja tehnološkog razvoja.

Kada je riječ o ekonomskom utjecaju generativne umjetne inteligencije na čitava svjetska gospodarstva, potrebno je krenuti od mikro razine, razine poduzeća. Upravo je implementacija umjetne inteligencije na razini individualnih poduzeća motor budućeg svjetskog gospodarstva. Zbog toga je posebno važno promotriti i analizirati utjecaj ove tehnologije na svakodnevne procese u različitim segmentima njihova poslovanja. Temeljno pitanje je na koji način generativna inteligencija danas utječe na digitalnu transformaciju procesa i poduzeća u cjelini.

1.1. Predmet i cilj rada

Predmet rada je utjecaj ChatGPT-a kao aplikativnog primata u području generativne umjetne inteligencije i mogućnosti njegove primjene u svakodnevnom poslovanju poduzeća. Cilj diplomskog rada je pružiti teorijsku osnovu i objasniti temeljne principe funkcioniranja generativne umjetne inteligencije pri čemu se potrebno dotaknuti i određenih tehnoloških karakteristika kao i pozadinskog načina funkcioniranja ChatGPT-a.

Zbog toga je potrebno primarno definirati obradu prirodnog jezika (engl. natural language processing - NLP) kao temelj generativne umjetne inteligencije, a zatim i vrste pristupa strojnom učenju te metode i modele obrade podataka koji imaju izuzetno velik utjecaj na pouzdanost generiranih učinaka. Adekvatna analiza same tehnologije upućuje na dublju analizu ChatGPT-a kao jednog od najnaprednijih, najpouzdanijih i najprepoznatljivijih jezičnih modela današnjice. Upravo kroz analizu samog alata cilj je doći do objašnjenja zbog čega je ova tehnologija i samo aplikativno rješenje ChatGPT u svega nekoliko dana doseglo onu razinu popularnosti za koju je nekim povijesnim inovacijama bilo potrebno nekoliko tjedana, mjeseci pa i godina. Ujedno, krajnji cilj rada je prikazati pojedine segmente poslovanja u kojima ChatGPT može imati golemu transformacijsku ulogu u povećavanju produktivnosti poduzeća.

1.2. Izvori podataka i metode prikupljanja

Za potrebe izrade diplomskog rada prikupljeni su i korišteni sekundarni izvori podataka. Izvor sekundarnih podataka pronalazi se u domaćoj i stranoj znanstvenoj i stručnoj literaturi. Pritom su analizirani relevantni znanstveni članci, objavljene knjige te raznovrsni internetski izvori, a sve s ciljem što opsežnijeg pregleda, kako tehnologije, tako i same aplikacije. Važno je naglasiti kako su većina izvora upravo digitalni primarno zbog inovativne prirode samog ChatGPT-a. Zbog relativno kratke „javne“ povijesti aplikacije ChatGPT, postoji relativno ograničena količina stručne literature o tom konkretnom rješenju. Ipak, sam koncept generativne umjetne inteligencije proučavan je već nekoliko desetljeća.

1.3. Sadržaj i struktura rada

Diplomski rad čini pet povezanih poglavlja pri čemu prvo poglavlje elaborira potrebu znanstvenih istraživanja u području generativne umjetne inteligencije. Drugo poglavlje pruža konceptualnu analizu pozadinske tehnologije, dok treće poglavlje detaljno analizira ChatGPT, tj. aplikativno rješenje. Konačno, najvažnije poglavlje za potrebe pružanja odgovora na ključna pitanja rada je upravo četvrto poglavlje koje analizira pozitivne i negativne reperkusije tehnologije na poslovne procese, predlaže i analizira područja maksimalnog utjecaja tehnologije na poslovanje te se dotiče potencijalnog budućeg razvoja i utjecaja ove tehnologije.

2. TEORIJSKA OSNOVA ZA OBRADU PRIRODNOG JEZIKA

U svrhu razumijevanja same tehnologije i njezina funkcioniranja, potrebno je pružiti kvalitetnu analizu osnovne tehnološke terminologije koja čini pozadinu aplikativnih rješenja usmjerenih na pružanje generativne umjetne inteligencije.

Za početak je potrebno razumjeti zašto se pojavljuje potreba za kvalitetnom, ali i brzom obradom i strukturiranjem podataka. Posljednja tri desetljeća obilježila je pojava i masovno prihvaćanje internetske infrastrukture, kako za potrebe privatnih, tako i poslovnih entiteta. Internet je do danas dokazao svoje disruptivne učinke u svakom životnom segmentu čovjeka. Jedna od temeljnih karakteristika interneta je centraliziranost. Sveopća prihvaćenost interneta omogućila je centralizaciju velike količine podataka na globalnoj razini. Gotovo je nemoguće zamisliti poslovanje bilo kojeg poduzeća današnjice čija temeljna infrastruktura nije temeljena na internetu kao tehnologiji. Internet kao infrastruktura i internetski preglednici kao nusproizvod interneta današnjim poduzećima omogućavaju lak i brz pristup velikim globalnim bazama podataka. Međutim, preglednici su u svom izvornom obliku vrlo ograničeni u kontekstu kvalitetne i brze pretrage upravo zbog nedostatka primjene strojnog učenja i obrade prirodnog jezika. Ova dva koncepta mogu osigurati budućim korisnicima interneta da u pojednostavljenom digitalnom okruženju svoja pretraživanja vrše brže te da im preglednici generiraju značajno kvalitetnije podatke sa značajno preciznijim i konkretnijim odgovorima na njihove upite.

Umjetna inteligencija može se promatrati kao znanstvena disciplina koja teži dekodirati ljudsko znanje i spoznaje te omogućiti računalima replikaciju tog istog znanja. Cilj stvaranja umjetne inteligencije i razvoja obrade prirodnog jezika je upravo omogućiti računalima stjecanje jednake količine svjetskog znanja koja bi osigurala kvalitetniju i bržu obradu dostupnih podataka. Kako bi se u nastavku rada moglo obraditi i kompleksnije termine, za početak je potrebno objasniti osnovne pojmove čije razumijevanje predstavlja osnovu koncepta umjetne inteligencije.

Inteligencija predstavlja izuzetno apstraktan i subjektivan pojam koji podrazumijeva „sposobnost učenja, razumijevanja, prosuđivanja i imanja mišljenja temeljenih na razumu.“ (Britannica, n.d.)

Može se uočiti kako svi navedeni elementi inteligencije sadrže karakteristične osobine čovjeka kao razumnog bića koje je sposobno na temelju postojećeg znanja, iskustava i spoznaja kreirati potpuno nova znanja.

Koncept umjetne inteligencije utemeljio je John McCarthy još 1955. godine pozivajući znanstvenike sličnih interesa na rad na znanstvenom projektu. Cilj je bio prepoznati karakteristike i osnovne principe u procesu stjecanja znanja opisujući te ih definirajući toliko detaljno da je takvo znanje moguće simulirati na strojevima. U svom pozivu (McCarthy, 1955) iznosi neke od temeljnih ideja budućeg razvoja umjetne inteligencije, ali i definira sedam inicijalno problematičnih aspekata umjetne inteligencije koje već tada prepoznaje:

1. Automatska računala: autor pretpostavlja kako bi automatizirani kalkulatori mogli simulirati stroj, ukoliko bi isti bio u mogućnosti obaviti posao. Također, nadodaje kako brzina i memorijski kapaciteti tadašnjih računala nemaju sposobnost simuliranja kompleksnih funkcija ljudskog mozga. No, uz rečeno, tvrdi kako glavna barijera nisu potkapacitirani strojevi, već ljudska nesposobnost pisanja programa koji maksimiziraju iskorištenost dostupnog znanja i podataka.
2. Programiranje računala u svrhu razumijevanja i korištenja ljudskog jezika: pretpostavlja visoku razinu manipulacije riječima uslijed nepisanih pravila razmišljanja i nagađanja ljudi. U tom kontekstu spominje i koncept generalizacije, a koji se odnosi na logiku shvaćanja pojedinih riječi u različitim kontekstima.
3. Neuronske mreže: koncept raspoređivanja neurona u svrhu oblikovanja koncepata
4. Teorija veličine izračuna: govori kako u slučaju precizno definiranog problema čiju je istinitost ili točnost odgovora moguće mehanički testirati, potencijalni način rješavanja je ispitivanje točnosti svih mogućih odgovora. U tom kontekstu uvodi kriterij učinkovitosti izračuna za što smatra potrebnom teoriju složenosti funkcija.
5. Samousavršavanje: autor navodi kako uistinu inteligentan stroj aktivnosti obavlja na one načine koji se mogu opisati kao samousavršavanje. Autor ovime želi utvrditi kako se inteligentnim strojem može smatrati onaj stroj koji teži kontinuiranoj optimizaciji svoga rada.
6. Apstrakcije: autor ih opisuje kao pokušaj klasifikacije apstrakcija i korištenja strojnih metoda za formiranje apstrakcija iz osjetilnih i drugih podataka.
7. Slučajnosti i kreativnost: autor tvrdi da je ključna spona između kreativnosti i nemaštovitog kompetentnog mišljenja uvođenje koncepta slučajnosti.

Može se zaključiti kako McCarthy definira umjetnu inteligenciju kao koncept koji teži simulaciji i pružanju svih inteligentnih karakteristika čovjeka računalima. Ujedno podrazumijeva i razumijevanje ljudskog jezika od strane računala. Simulacija znanja i obrade podataka može se koristiti u različite svrhe, počevši od automatizacije jednostavnih i

svakodnevnih procesa ili aktivnosti pa sve do obrade velike količine podataka, izrade prognostičkih modela na temelju povijesnih vrijednosti i, u konačnici, donošenju važnih i strateških odluka prilikom upravljanja različitim entitetima.

Hintze (2016) pruža zanimljiv pogled i kategorizaciju četiri vrste umjetne inteligencije. Posebno je zanimljivo analizirati neočekivani eksponencijalni razvoj ove tehnologije gotovo desetljeće nakon nastanka članka. Ono što autor posebno naglašava u samom članku je da se u analizama utjecaja umjetne inteligencije kontinuirano zanemaruje činjenica kako sam razvoj umjetne inteligencije utječe na brzinu budućeg razvoja i dodatnog napretka te tehnologije. Što računala brže i kvalitetnije obrađuju podatke i što je više podataka pruženo samom računalu u procesu učenja, to će brže i kvalitetnije učinke tehnologija ostvarivati u budućnosti. Zbog navedenog autor smatra da su učinci umjetne inteligencije u kratkom i srednjem roku na svim razinama izuzetno podcijenjeni. No, autor smatra da, bez obzira na značajnu brzinu i snalažljivost u rješavanju kompleksnih kalkulacija, inteligentnim sustavima nedostaju sljedeći čimbenici i karakteristike koji bi ga učinili spremnim nadići ljudske sposobnosti i inteligenciju:


- Reaktivnost strojeva: sposobnost povezivanja i formiranja sjećanja te donošenje informiranih odluka na temelju prethodnih iskustava
- Neograničena memorija: u datom trenutku prikupljeni i analizirani podaci su isključivo prolazni i nisu svrsishodno skladišteni za potrebe donošenja budućih odluka
- Teorija uma: prema autoru ključan segment po kojemu se budući pametni strojevi mogu razlikovati od današnjih, a označava percepciju okoline strojeva od strane njih samih i svijest da različiti akteri u njegovu okruženju zbog različitih motiva i namjera mogu imati različite poglede, razmišljanja te, potaknuti emocijama, donositi različite odluke u sličnim ili identičnim situacijama
- Samosvijest: izgradnja svjesnih strojeva kao posljednji stadij razvoja ove tehnologije

Nastavno na analizu autora, legitimno je postaviti pitanje razumiju li ljudi danas uopće psihološku pozadinu vlastitog djelovanja, ponašanja i spoznavanja. Ono što je potrebno kako bi se kreirali samosvjesni strojevi koji poznaju teoriju uma je replicirati upravo ljudsko djelovanje. Preostaje analizirati može li čovjek reproducirati i replicirati svoju reakciju uz upitan stupanj razumijevanja vlastitog djelovanja. Uzimajući u obzir eksponencijalan napredak ove tehnologije, ali i cjelokupnost razvoja civilizacije do danas, nije sporno kako će u nekom trenutku ovaj stadij razvoja biti dosegnut. Pitanje je samo na koji način i u kojem vremenu će

ljudi uspjeti adekvatno informacijski opskrbiti različite modele kako bi mogli producirati ista ili slična znanja.

Prvenstveno je važno konceptualno objasniti hijerarhijsku podjelu pojedinih segmenata umjetne inteligencije (Slika 1) kako bi se u cijelosti razumjela uzročno posljedična veza između velikih jezičnih modela, generativne umjetne inteligencije, neuronskih mreža, dubokog i strojnog učenja te umjetne inteligencije kao najšireg koncepta.

Slika 1: Hijerarhijska segmentacija područja umjetne inteligencije



Izvor: Izrada autora prema Li, S., Deng, Y. Q., Zhu, Z. L., Hua, H. L., & Tao, Z. Z. (2021). A comprehensive review on radiomics and deep learning for nasopharyngeal carcinoma imaging. *Diagnostics*, 11(9), 1523.

Danas se umjetna inteligencija kao područje istraživanja promatra u značajno širem obujmu nego li je to inicijalno bila prije svega nekoliko desetljeća. Prema Zhou i sur. (2020) umjetna inteligencija danas objedinjuje te predstavlja svojevrsni krovni pojam za nekoliko različitih područja poput obrade prirodnog jezika, strojno učenje, automatizaciju i robotiku, automatsko programiranje.

Analizirajući umjetnu inteligenciju, nužno je spomenuti dvije sastavne discipline koje ju u tehnološkom smislu kroje, a to su strojno i duboko učenje. Obje vrste učenja predstavljaju različite oblike umjetne inteligencije, a snažnija ili slabija učestalost primjene pojedinog učenja ovisi o krajnjem cilju i tipu podataka koje se teži interpretirati. Profesor sa Sveučilišta u Stanfordu, Christopher Manning, u svom kratkom pregledu definicija vezanih uz umjetnu inteligenciju pojašnjava razlike između strojnog i dubokog učenja.

Tako Manning (2020) strojno učenje objašnjava kao segment područja umjetne inteligencije čiji su predmet proučavanja računala, a čiji je cilj povećati svijest i osnažiti percepciju računala o njihovom okruženju, unaprijediti njihova razmišljanja i donošenje odluka temeljem iskustvenih podataka. Autor navodi kako je proces strojnog učenja interdisciplinarni proces u kojemu se primjenjuje i isprepliće nekoliko različitih znanstvenih disciplina poput računarstva, statistike, psihologije, neuroznanosti i ekonomije. Upravo iz širine i različitosti znanstvenih disciplina prisutnih u procesu strojnog učenja može se uočiti važnost društvenih znanosti i primjene njihovih dostignuća za razvoj umjetne inteligencije.

Za razliku od strojnog učenja, autor u nastavku definira i koncept dubokog učenja te tvrdi kako se isti bazira na višeslojnim neuronskim mrežama. Za razliku od strojnog učenja kojemu je potrebna velika količina kvalitetno strukturiranih podataka, cilj je dubokog učenja postići iste učinke bez prisutnosti čovjeka, a temeljene na razvoju višeslojnih algoritama i neuronskim mrežama. Razvoj neuronskih mreža upravo je ključan čimbenik za diverzifikaciju strojnog i dubokog učenja te igra presudnu ulogu u budućoj prisutnosti čovjeka prilikom daljnjeg razvoja modela.

Prilikom usporedbe strojnog i dubokog učenja, važno je izdvojiti i perspektivu Ericksona i sur. (2017) koji strojno učenje promatraju isključivo kao tehnologiju, tj. alat za realizaciju umjetne inteligencije koja je, pogonjena algoritmima za raščlambu i učenje iz dostupnih podataka, sposobna donositi odluke i predviđati događaje u realnom vremenu. Uočavaju kako se ovakva tehnologija značajno razlikuje od prethodnih softverskih rješenja koja su bila isključivo usmjerena na rješavanje specifičnih zadataka.

U kontekstu teorijske analize umjetne inteligencije kao značajno šireg koncepta, nakon strojnog učenja, potrebno je dotaknuti se i dubokog učenja kao segmenta umjetne inteligencije podređenog strojnom učenju. Duboko učenje je, dakle, sastavni dio strojnog učenja kao šireg termina, a čine ga algoritmi kao komponente dubokog učenja.

Thomas i sur. (2009) algoritme prepoznaju kao jasno definirane računalne procedure koje na temelju zadanih ulaznih vrijednosti kreiraju novi izlazni skup vrijednosti. Smatraju kako algoritmi predstavljaju unaprijed definirani skup konkretnih pravila i računalnih koraka koji pretvaraju ulazni skup vrijednosti u novodefinirane učinke. Prema autorima, algoritmi predstavljaju onu računalnu proceduru koja prepoznaje ulazne vrijednosti, temeljeno na ulaznoj vrijednosti prepoznaje unaprijed definirane željene učinke kao izlaznu vrijednost, a algoritam predstavlja onaj skup pravila i proceduru putem koje računalo dolazi upravo do željenog učinka.

Konačno, prilikom teorijskog pregleda umjetne inteligencije kao šireg koncepta, potrebno je spomenuti i autonomne sustave koje Watson i Scheidt (2005) promatraju kao sustave koji su sposobni i imaju mogućnost prilagođavati se neočekivanim događajima u svojem okruženju. Ovakvi sustavi ne zahtijevaju čovjekovu prisutnost, već su u stanju samostalno odgovarati na nepredviđene situacije.

Goertzel (2014) promatra i istražuje desetljetni smjer razvoja i implementacije umjetne inteligencije na strateškoj razini. Propitkivanje strateške razine primjene umjetne inteligencije podrazumijeva dilemu o upotrebi i korištenju umjetne inteligencije za rješavanje vrlo specifičnih, koncizno definiranih zadataka ili pak razvoj generalne umjetne inteligencije koja će imati značajno širu primjenu. Autor zaključuje kako su namjere istraživača tijekom desetljetnog razvoja umjetne inteligencije intuitivno odlazile u smjeru razvoja rješenja specifične i konkretne primjene. Međutim, naglašava kako se smjer razmišljanja istraživača u posljednjih nekoliko godina značajno promijenio te kako se sve češće javljaju težnje za razvojem generalne inteligencije koja bi podrazumijevala razvoj softverskih i hardverskih rješenja i sustava koja bi izjednačavala ili nadilazila kapacitete računala u usporedbi s ljudskim kapacitetima.


Kurzweil (2005) u svom radu na temu etike i tehnologije, a u kojoj propitkuje buduću ulogu tehnologije u čovjekovu život, po prvi puta spominje koncept razvoja umjetne inteligencije specifične namjene. Takav koncept naziva uskom inteligencijom, engl. narrow artificial intelligence - AI, kasnije nazvan engl. Artificial Narrow Intelligence - ANI, a objašnjava ga kao skup rješenja temeljenih na umjetnoj inteligenciji koja su usmjerena na pružanje jednog, specifično usmjerenog, inteligentnog rješenja za jedan specifičan kontekst.

Nužno je shvatiti kako je za bilo kakvu modifikaciju ovakvih specifičnih sustava potrebna čovjekova uloga. Uz naveden značajan doprinos u kontekstu uvođenja ovog termina, autor iznosi i nekoliko značajnih teza koje ukazuju na moguće reperkusije primjene umjetne

inteligencije, a po prvi puta spominje termin tehnološke singularnosti kojim objašnjava hipotetsku situaciju u budućnosti, točku u vremenu u kojoj eksponencijalni i izuzetno brz napredak tehnologije dovodi do nepovratne transformacije ljudske civilizacije.

Navodi kako je čovječanstvo na granici prelaska iz većinom horizontalne u snažno vertikalnu krivulju razvoja (Grafikon 1), tj. na granici prelaska iz linearnog u eksponencijalni razvoj tehnologije. Također, smatra kako će nadolazeće razdoblje tehnološke singularnosti obilježiti spajanje biološkog i računalnog znanja te da će upravo ljudsko znanje postati nebiološko. Ljudsko znanje može postati nebiološko u nekoliko scenarija, a neki od takvih scenarija su skladištenje ukupnog ljudskog znanja u računalima ili pak kreiranje sintetičkog znanja od strane samih računala. Autor takvo novonastalo okruženje vidi kao proizvod sinergije i zajedničke evolucije ljudi i računala.

Grafikon 1: Prikaz koncepta tehnološke singularnosti



Izvor: Izrada autora prema BotPenguin. (n.d.). Technological singularity. BotPenguin. Preuzeto sa: <https://botpenguin.com/glossary/technological-singularity>

Za razliku od uske umjetne inteligencije kao koncepta rješavanja specifičnih i uskih problema putem jasno usmjerenih sustava, suprotnost tom konceptu predstavili su Taylor i sur. (2008) govoreći o generalnoj inteligenciji, engl. Artificial General Intelligence - AGI. Generalnu umjetnu inteligenciju vide kao jedinstven sustav koji se samostalno prilagođava okruženju i okolnostima, a njegov razvoj temeljen je na konceptu prenošenja znanja. Upravo zbog karakteristike prenošenja znanja, sama računala imaju mogućnost, ovisno o različitim kontekstima, prenositi znanje i koristiti ga u različitim kontekstima za različite potrebe. Ovakvi sustavi imaju značajno veći obujam informacija i znanja, a imaju potpuno drugačiji cilj i svrhu.

Ključna diferencijacija prema autorima proizlazi iz činjenice da cilj sustava za generalnu umjetnu inteligenciju nije riješiti specifičan problem u zadanom kontekstu kao kod uske umjetne inteligencije. Takvi sustavi imaju puno širu primjenu i usmjereni su na razumijevanje samih svojstava zadanih ulaznih vrijednosti u sustavu kako bi, primjenom tog i prethodno stečenog znanja te njegovim oblikovanjem, bili sposobni pružiti rješenje bilo kojeg zadatka ili problema, neovisno o njegovoj kompleksnosti.

U kontekstu diplomskog rada, nameće se pitanje treba li ChatGPT aplikaciju promatrati kao generalnu ili kao usku umjetnu inteligenciju. Služba Europskog parlamenta za usluge parlamentarnog istraživanja – EPRS (EPRS, 2023) u svojoj se pripremi i analizi za zastupnike Europskog parlamenta bavi upravo temom klasifikacije aplikacije ChatGPT u okvirima područja umjetne inteligencije. Pritom, autori jasno naglašavaju razlike između ranije spomenute ANI i AGI umjetne inteligencije, jasno dajući do znanja kako je upravo razvoj velikih jezičnih modela, engl. large language models – LLM, doveo do značajnog napretka u razvoju generalne umjetne inteligencije.

Iako autori strateškog dokumenta aplikativno rješenje ChatGPT nazivaju umjetnom inteligencijom opće namjene, sam GPT jezični model, tj. ChatGPT aplikacija prilikom postavljanja istog pitanja odgovara i definira sebe kao primjer uske umjetne inteligencije. Pritom, ostaje nejasno misli li se u analizi europskog tijela na ChatGPT kao alat umjetne inteligencije opće namjene iz perspektive širine područja u kojima može biti primijenjen ili pak na samu svrhu i karakteristike generalne umjetne inteligencije koje, s obzirom na navedeno, u ovom trenutku sam jezični model i aplikacija ne posjeduju.

Slika 2: Klasifikacija ChatGPT-a u domenu uske umjetne inteligencije

Možeš li mi molim te u nekoliko riječi odgovoriti je li ChatGPT aplikacija primjer generalne umjetne inteligencije (artificial general intelligence) ili pak primjer uske umjetne inteligencije (artificial narrow intelligence)?



ChatGPT je primjer uske umjetne inteligencije (artificial narrow intelligence).



Izvor: Izrada autora na osnovu odgovora aplikacije ChatGPT

Ovakvu klasifikaciju aplikacija (ChatGPT, 2024) objašnjava svojim konceptom i dizajnom koji su usmjereni isključivo na izvršavanje karakterističnih zadataka ili problema. Nadalje, objašnjava kako ChatGPT jezični model nema sposobnost općeg razumijevanja i učenja na način na koji to može činiti ljudska inteligencija, već je jezični model obučen isključivo za razumijevanje i generiranje prirodnog jezika.

Razloge svrstavanja ChatGPT-a u kategoriju uske umjetne inteligencije Courtad (2023) u svojoj analizi elaborira sljedećim argumentima:

- Alat je usmjeren isključivo na razumijevanje prirodnog jezika i generiranje pri čemu može izvršavati različite zadatke poput odgovaranja na različita pitanja kroz generiranje tekstualnih poruka, dok nema sposobnost prepoznavanja i razumijevanja zadanog pitanja poput prepoznavanja slika i prenošenja znanja iz različitih područja u svrhu rješavanja jedinstvenog problema
- Alat ima ograničeno razumijevanje podataka za koje jezični model nije unaprijed istreniran zbog čega ne može pružiti istu razinu pouzdanosti u razumijevanju upita poput ljudske inteligencije
- Alat nema mogućnost prenošenja znanja između različitih područja što ga ograničava u generalnoj i općoj primjeni generiranih tekstova u različitim područjima
- Zbog nedostatka generalne i emocionalne inteligencije te mogućnosti promišljanja, a uslijed nesposobnosti samostalnog učenja, alat teško spoznaje nove izazove i koristi prethodna iskustva i znanja koja nisu bila dijelom procesa treniranja jezičnog modela

Za sam kraj uvodnog, teorijskog dijela, potrebno je definirati i generativnu umjetnu inteligenciju te velike jezične modele.

Izraz generativna umjetna inteligencija autori Feuerriegel i sur. (2024) vide kao skup računalnih metoda koje su, iz podataka putem kojih su trenirani i obučavani, sposobni proizvesti naizgled originalan i smislen sadržaj poput teksta, slike ili zvuka. Autori pritom spominju neke od karakterističnih i danas prepoznatljivih aplikacija poput DALL-E 2 i Copilota, a uz navedene i jezični model GPT-4. Autori također navode kako generiranje novih tekstova ili slika zasigurno neće biti najvažnija funkcija ovakvih modela, već naglašavaju njihovu važnost prilikom interakcije s čovjekom pri čemu mogu predstavljati inteligentne sustave koji će čovjeku moći pružiti sustav odgovora na pitanja.

DALL-E 2 je sustav umjetne inteligencije koji ima sposobnost kreirati realistične slike iz opisanog unosa putem prirodnog jezika. Dakle, to je aplikacija koja koristi jezični model kao dio svoje funkcionalnosti, a koja tekstualne unose može transformirati u vizualan oblik.

Važno je uočiti razliku između ChatGPT-a i GPT-4. Sam GPT-4 predstavlja jezični model koji se može koristiti u različitim aplikacijama za obradu prirodnog jezika. ChatGPT je aplikativno rješenje i egzaktan primjer implementacije GPT-4 jezičnog modela. Suprotno, GPT-4 predstavlja napredni, generativni, veliki jezični model, a koji je osnova funkcioniranja ChatGPT aplikacije.

Prema Min i sur. (2023), veliki jezični modeli (LLM) su modeli bazirani na tehnologiji dubokog učenja. Cilj ovakvih modela je kvalitetno razumijevanje unosa i generiranje prirodnog jezika na temelju zadanog unosa. Autori pritom navode neka od ključnih područja u kojima veliki jezični modeli pronalaze svoju najznačajniju pripremu poput automatskog kreiranja sažetaka teksta, međujezičnog prevođenja i pružanja odgovora na temelju zadanog pitanja.

Može se zaključiti kako veliki jezični modeli (LLM) i alati poput ChatGPT-a, izgrađeni na njihovim temeljima, značajno povećavaju važnost primjene strojnog i dubokog učenja. Veliki jezični modeli imaju sposobnost generiranja novog tekstualnog, audio i videozapisa što ih čini oblikom generativne umjetne inteligencije.

2.1. Osnovni koncepti i izazovi u obradi prirodnog jezika (NLP)

Za kvalitetnije razumijevanje funkcioniranja umjetne inteligencije i ChatGPT jezičnog modela, potrebno je detaljno obraditi i samo područje obrade prirodnog jezika te kontekst u kojemu je prirodni jezik važan za budućnost razvoja umjetne inteligencije.

Obrada prirodnog jezika je „skup računalnih tehnika za analizu i utjelovljenje tekstova koji se prirodno pojavljuju na jednoj ili više razina lingvističke analize, a u svrhu obrađivanja prirodnog jezika na način sličan čovjekovom s krajnjim ciljem primjene za različite zadatke i aplikacije“ (Liddy, 2001). Ista autorica u nastavku svog pregleda objašnjava važnost svakog pojedinog segmenta definicije obrade prirodnog jezika. Tako naglašava kako su različite tehnike kvalitetnije ili manje kvalitetne za obradu drugačijih jezičnih oblika. Tekstove koji se prirodno pojavljuju objašnjava kao bilo koje oblike tekstova, verbalne ili pisane, a ključna karakteristika im je ta da ljudima služe za međusobno sporazumijevanje.

Autorica kao temeljni problem vidi razinu lingvističke analize. Naglašava kako različiti pristupi obradi prirodnog jezika te slabija ili snažnija razina lingvističke analize postižu i rezultate

različite kvalitete. Kako temeljnom svrhom obrade prirodnog jezika smatra dostizanje razine obrade jezika sličnom čovjeku, smatra kako je upravo to pokazatelj da se radi upravo o obliku umjetne inteligencije. Konačno, autorica pruža zanimljivu tezu kako obrada prirodnog jezika nije ni u kom slučaju sama sebi svrha, već isključivo služi kao alat za izvršavanje određenih zadataka.

U tom kontekstu, vrlo opsežan pregled važnosti obrade prirodnog jezika i povezanosti iste s razvojem umjetne inteligencije, pružaju Radev i Mihalcea (2008). Autori tvrde kako su u smislenim i povezanim jezičnim cjelinama, neovisno o veličini jezične jedinice i o tome radi li se o riječima, frazama ili pak čitavim rečenicama, upravo te jezične jedinice uvijek povezane na različite načine. Smatraju kako su relacije među jezičnim jedinicama ključan čimbenik koji im pruža i pridaje opće značenje. Analizirajući povijest umjetne inteligencije, naglašavaju kako su od samih početaka razvoja umjetne inteligencije, semantičke mreže bile smatrane adekvatnim prikazom skladištenja jezičnih jedinica i relacija koje ih povezuju. Dodaju kako je upravo razvoj ovakvog koncepta pomogao računalima i doprinio njihovom razvoju razumijevanja.

Može se zaključiti kako je obrada prirodnog jezika računalna disciplina koja predstavlja samo jedan dio računalne znanosti umjetne inteligencije, a čiji je cilj pokušati definirati obrasce ljudskog ponašanja. Na ovaj se način ljudski obrasci razmišljanja i zaključivanja mogu uspješno prenijeti računalima u svrhu buduće obrade, analize i generiranja podataka. Glavni cilj razvoja obrade prirodnog jezika je upravo pronaći jasno definirane obrasce ljudske percepcije i razumijevanja različitih poveznica među određenim jezičnim jedinicama. Dakle, cilj je definirati razloge i načine povezivanja određenih jezičnih jedinica u smislene cjeline.

2.1.1. Osnovni elementi jezika i njihova obrada u NLP

Osnova za obradu osnovnih elemenata jezika može se pronaći u analizi ElHousienyja (2024) koji kao ključne elemente prirodnog jezika promatra semantiku, pragmatiku, morfologiju, fonologiju i sintaksa. U nastavku će biti pružen pregled osnovnih elemenata prirodnog jezika te uloga tih elemenata u uspješnom prijenosu znanja računalima.

Prema Cambria i White (2014), semantika u obradi prirodnog jezika (NLP) fokusira se na razumijevanje značenja riječi, fraza i rečenica, te njihovih međusobnih odnosa. Ova analiza omogućava sustavima da prepoznaju kontekst i implicitne informacije, čime prelaze izvan same sintakse i postaju sposobni za složenije jezične zadatke poput prevođenja i ekstrakcije znanja. Govore kako kroz semantičke reprezentacije, NLP sustavi mogu precizno enkodirati i

manipulirati značenjem što je ključno za dublje razumijevanje i interpretaciju ljudskog jezika. Može se reći kako autori naglašavaju činjenicu da semantika predstavlja puno više od samog prepoznavanja osnovnih gramatičkih pravila i struktura. Dodaju kako ideja uvođenja semantike donosi razumijevanje složenih značenja između riječi što računala čini značajno učinkovitijima u procesuiranju ljudskog jezika, a u nastavku svog istraživanja autori razvoj semantike smatraju ključnim segmentom razvoja velikih i sofisticiranih NLP sustava.

Može se zaključiti kako razvoj semantike u sklopu obrade prirodnog jezika uistinu predstavlja važnu barijeru koja će računala približiti stupnju ljudskog procesuiranja međusobnog prirodnog jezika. Pridavanjem značenja, konteksta i cjelovitog razumijevanja jednostavnijih gramatičkih konstrukcija, kapaciteti razumijevanja umjetne inteligencije postaju značajno precizniji, kvalitetniji i u konačnici pouzdaniji.

Fonološka obrada je prema Tayloru i sur. (2008) ključna za NLP sustave, a posebice u disciplini automatskog prepoznavanja i sinteze govora te u tehnologijama čija je svrha transformacija teksta u govor. Autor smatra kako fonološko znanje omogućuje sustavima za automatsko prepoznavanje govora kvalitetnije upravljanje varijacijama u govoru, poput različitih naglasaka i brzine govora, što poboljšava njihovu točnost. Također, tvrdi kako fonološka analiza osigurava razumijevanje zvučne strukture jezika, što je bitno za segmentaciju govora u smislene jedinice i prepoznavanje fonema. U sintezi govora, precizno modeliranje fonoloških aspekata omogućava stvaranje govora koji vjerno oponaša ljudsku intonaciju i ritam.

Može se uočiti kako različite karakteristike prirodnog jezika mogu imati različitu te veću ili manju primjenu ovisno o području primjene, tj. konačnom aplikativnom rješenju, njegovoj svrsi i problemu kojeg za krajnjeg korisnika sustav rješava. Govoreći o aplikacijama budućnosti koje će biti temeljene na umjetnoj inteligenciji, može se zaključiti kako će neki elementi prirodnog jezika poput fonologije pružati značajno veću vrijednost u aplikacijama temeljenim na zvuku, nego li u određenim segmentima poput sinteze i generiranja pisanih tekstova. Dakle, poznavanje i razumijevanje fonologije i njezinih karakteristika pomaže omogućiti kvalitetnije snalaženje s govornim manipulacijama.

Morfološka analiza i segmentacija riječi jednako su važni za obradu prirodnog jezika (Manning i Schutze, 1999). Razlaganjem riječi na osnovne morfeme, sustavi mogu bolje upravljati fleksijama, derivacijama i složenim oblicima, što je posebno važno za jezike bez jasnih granica između riječi. Ove tehnike omogućuju precizno prepoznavanje i interpretaciju riječi, čime se

poboljšava učinkovitost u zadacima poput prevođenja, pretraživanja informacija i označavanja vrsta riječi.

Dodatno je za potpuno razumijevanje morfološke analize potrebno objasniti i pojam fleksije. Fleksije u lingvistici predstavljaju promjene oblika riječi, prilikom kojih se ne mijenja njihova gramatička kategorija (Hrvatska enciklopedija, 2024). Pritom je potrebno razlikovati fleksije od derivacija riječi. Za razliku od fleksija prilikom kojih promjena ne dolazi do promjene gramatičke kategorije riječi, derivacije označavaju ujedno i promjenu kategorije riječi. Autori enciklopedije također naglašavaju kvalitetan primjer fleksije, a to je pomoćni glagol biti čiji se infinitiv značajno razlikuje od paradigme istog glagola u prezentu ili pak prošlom i budućem glagolskom vremenu.

Konačno, posljednji važan element prirodnog jezika je sintaksa čiju najvažniju svrhu Goldberg (2022) vidi u analizi sintaktičke strukture što sustavima za obradu prirodnog jezika omogućava razumijevanja hijerarhije jezika. Autor naglašava ovu sposobnost sustava prilikom izvršavanja zadataka poput parsiranja, generiranja rečenica i prevođenja. Dubinska sintaksna analiza omogućava značajno preciznije razumijevanje strukture rečenice, identificirajući složene gramatičke odnose i hijerarhiju između različitih rečeničnih dijelova. Time se računalima omogućava razumijevanje cjeline konteksta i kompleksnih jezičnih konstrukcija.

2.1.2. Izazovi u obradi prirodnog jezika

Obrada prirodnog jezika je složen i kompleksan proces u usporedbi s obradom ostalih vrsta podataka. Nekoliko je razloga za to, a koji su objašnjeni u nastavku. Priroda kompleksnosti prirodnog jezika leži prije svega u različitosti strukturiranih i nestrukturiranih podataka.

U svom pregledu, čiji je naziv definicija, karakteristike i usporedba strukturiranih i nestrukturiranih podataka, Aukstikalnyte, R. (2023) tvrdi kako su strukturirani podaci organizirani u specifičan format prije samog procesa pohrane, što ih čini lakšima za obradu algoritmima strojnog učenja zbog njihove strukturiranosti i uređenosti općenito. Obrnuto, analizirajući nestrukturirane podatke poput teksta, zvuka i videa, autor naglašava kako ovakvi podaci nemaju prethodno definiran model te zahtijevaju značajno naprednije alate poput obrade prirodnog jezika (NLP) kako bi se detaljnijom analizom mogli izvoditi različiti zaključci i, u konačnici, korisne i kvalitetne informacije.

Dodatno, sličnu perspektivu pružaju i Verspoor i Cohen (2013) tvrdeći kako je obrada prirodnog jezika (NLP) u stvari proces pretvaranja nestrukturiranih podataka, poput pisanog teksta i govornog jezika, u strukturirani format. Ovu pretvorbu autori smatraju ključnom jer

tvrdi kako velika većina podataka, njih otprilike 80 posto, spada u nestrukturirane formate i oblike koji zahtijevaju specijalizirane alate za učinkovitu analizu i izvlačenje relevantnih spoznaja.

Dakle, temeljna razlika u pristupu obradi podataka nalazi se u činjenici kako se strukturiranim podacima i njihovoj obradi mora pristupati značajno drugačije nego li nestrukturiranim podacima. S obzirom da su strukturirani podaci najčešće kvantitativni, može se zaključiti kako postoje značajno veći izazovi prilikom obrade kvalitativnih podataka. Nakon uvoda u temeljne razlike između obrade prirodnog jezika i drugih vrsta podataka, konačno se dolazi do konkretnih karakteristika prirodnog jezika koje njegovu obradu čine kompleksnijom. Može se reći kako čitava premisa o složenosti prirodnog jezika proizlazi iz raznolikosti načina na koji svaki individualac komunicira. Komunikacijske karakteristike i specifičnosti svakog individualca čine generalno razumijevanje jezika računalima značajno kompliciranijim.

Konkretnu analizu uzroka kompleksnosti obrade prirodnog jezika pružaju Manning i Schutze (1999) koji govore kako se obrada prirodnog jezika suočava s velikim brojem izazova, počevši od inherentne dvosmislenosti jezika, sve do izazova i poteškoća u tumačenju konteksta i složenosti ljudske komunikacije. Autori navode kako se kompleksnost dodatno produbljuje zbog raznolikosti u upotrebi jezika, kulturnih razlika i stvaranjem potrebe za velikim skupovima podataka kako bi se noviji modeli učinkovito trenirali.

2.1.3. Etička pitanja i odgovornost u razvoju i primjeni obrade prirodnog jezika

Umjetna inteligencija će definitivno u budućnosti oblikovati civilizacijski napredak. Zbog te je činjenice izuzetno važno i potrebno detaljno analizirati moguće reperkusije u kontekstu potencijalne zlouporabe umjetne inteligencije u budućnosti. U tom se kontekstu nameću neka etička pitanja i odgovornosti koje je potrebno pravovremeno uočiti.

Prvo važno etičko pitanje je pitanje privatnosti i obrade podataka. U tom je kontekstu izuzetno važno promatrati na koji način se podaci obrađuju i pohranjuju. Također, posebice je važno govoriti u kontekstu aktualne europske regulative i Opće uredbe o zaštiti podataka, engl. General Data Protection Regulation – GDPR). Opća uredba o zaštiti podataka je pravni okvir regulatornih tijela Europske unije čiji je cilj pružiti jasan okvir i smjernice kojih se unutar Europske Unije potrebno pridržavati prilikom prikupljanja, obrade, pohrane i prijenosa osobnih podataka osoba (Europska komisija, 2016). Na ovaj se način, prema općoj uredbi, postiže visok stupanj zaštite osobnih podataka i privatnosti. Kroz donošenje regulative, pojedincima se

omogućuje kvalitetnije i jasnije upravljanje dostupnošću vlastitih podataka, a samim time posljedično se utječe i na njihovu sigurnost.

O etičkim pitanjima i odgovornosti, kao i pitanjima privatnosti u budućoj kohabitaciji čovjeka i umjetne inteligencije govori i Dignum, V. (2019) koji u svom radu na temu odgovorne umjetne inteligencije tumači sve veću integraciju sustava umjetne inteligencije i obrade prirodnog jezika u čovjekovu svakodnevicu. Autor tvrdi kako je potrebno osigurati, i iz perspektive programera koji razvijaju sustave inteligencije, ali i iz perspektive čitavih organizacija, da takvi sustavi ne mogu biti štetni za krajnjeg korisnika i da ne zloupotrebljavaju privatne podatke te osjetljive osobne informacije.

Drugi važan etički čimbenik prilikom razvoja velikih jezičnih modela i umjetne inteligencije generalno je pristranost. O mogućoj pristranosti govore Gallegos i sur. (2024) tvrdeći kako veliki jezični modeli, učeći iz ogromnih količina podataka prikupljenih i dostupnih na internetu, u konačnici mogu biti izmanipulirani, a sadržaj koji pružaju krajnjim korisnicima pristran, prepun stereotipa i diskriminatoran. Na ovaj način prema autorima modeli mogu pojačati društvene podjele, polarizaciju i nepravdu zbog čega ih potrebno pravovremeno prepoznavati i minimizirati.

Društvene nepravde uzrokovane nepravilnim treniranjem velikih jezičnih modela, znanstveno su proučavali i Mehrabi i sur. (2021) koji u svojoj analizi spominju sve veću implementaciju umjetne inteligencije i njenu integraciju u određene društvene procese poput zapošljavanja, zdravstva, prava i obrazovanja. Tumače kako neadekvatno istrenirani modeli mogu podupirati pristranost koja u sličnim društvenim procesima može dovesti do nepravde i, u konačnici, spolne, rasne, etničke ili nekog drugog oblika diskriminacije.

Uzimajući u obzir činjenicu da je umjetna inteligencija u najširoj populaciji svoju popularnost doživjela tek prije nekoliko godina, posebno je važno analizirati kako se pristranost može odraziti i na opću razinu buduće prihvaćenosti tehnologija vezanih uz umjetnu inteligenciju. Jednom razvijeno nepovjerenje krajnjih korisnika može ih značajno udaljiti od same ideje tehnologije zbog čega je posebno važno analizirati kako pristranost utječe na buduću odluku o korištenju alata umjetne inteligencije.

Crawford (2021) u svom radu stavlja velik naglasak i upozorenje na pristranosti unutar sustava umjetne inteligencije. Autorica tvrdi kako pojava pristranosti može uvelike narušiti povjerenje javnosti u samu tehnologiju. Navodi kako, u slučaju percipiranja pristranosti i nepravednosti ili

pak diskriminacije, krajnji korisnici mogu stvoriti averziju prema tehnologiji i razviti otpor prema njezinom korištenju.

Pretpostavljajući kako je pojava svake nove tehnologije pozitivna dugoročna promjena za društvo u cjelini, usporavanje opće prihvaćenosti umjetne inteligencije predstavlja barijeru za brži i kvalitetniji napredak čitavog društva. Zbog toga posljedice pristranosti velikih jezičnih modela mogu biti značajno veći i usporavajući faktor društvenog razvoja u budućnosti. U takvoj situaciji društvo ne koristi maksimalan potencijal dostupnih tehnologija.

Konačno, važno je napomenuti kako bilo kakav oblik društvene segregacije i diskriminacije u većini razvijenih zemalja podliježe kaznenoj odgovornosti, uslijed čega i sama poduzeća koja razvijaju alate umjetne inteligencije i velike jezične modele moraju biti izuzetno oprezna i tijekom samog razvoja pravilno usmjeravati razvoj umjetne inteligencije kako bi izbjegla moguće tužbe i pravne sankcije (Barocas i sur., 2019).

Kako bi se izbjegla pristranost velikih jezičnih modela, nameće se nekoliko jasnih rješenja koja mogu pomoći u kreiranju jasnijeg i pravednijeg tehnološkog okruženja u budućnosti.

Algoritamska transparentnost je koncept u akademskoj zajednici koji objašnjava koliko je važno omogućiti razumijevanje načina putem kojih modeli dolaze do svojih odluka. Na ovaj se način osigurava da model ne generira i ne producira nepravedne rezultate ili odražava pristranost (Selbst i Barocas, 2018). Za autore transparentnost algoritama nije samo izvedbeni izazov u tehničkom smislu, već odraz savjesnog postupanja prilikom razvoja i praćenja etičkih standarda.

Brojni jezični modeli i alati umjetne inteligencije imaju za svrhu biti dostupni i rasprostranjeni široj društvenoj populaciji kroz osiguran visok stupanj integracije s brojnim drugim aplikacijama za svakodnevnu upotrebu. U eri digitalnih tehnologija, kibernetička sigurnost predstavlja ključan aspekt za same korisnike. Različiti korisnici aplikacija imaju i različite razine digitalne pismenosti i prepoznavanja potencijalnih prijetnji i opasnosti u digitalnom okruženju. Veliki jezični modeli će u budućnosti biti značajno veći i kompleksniji nego li su to danas. Zbog toga je upravo prilikom ranih faza razvoja jezičnih modela potrebno obratiti veliku pozornost na sigurnosni aspekt u različitim segmentima funkcioniranja modela o čemu u svojim istraživanjima govore Jin i sur. (2020) naglašavajući ranjivosti i opasnosti koje se nalaze u samoj arhitekturi današnjih modela. Autori smatraju kako su upravo nedostaci u arhitekturi povod potencijalnim napadačima koji ih mogu koristiti za kreiranje štetnog sadržaja zbog čega zazivaju stvaranje otpornih obrambenih mehanizama.

Dakle, veći stupanj integracije i rasprostranjenost jezičnih modela čini ih interesantnijim objektom zlonamjernih napada. Njihov integritet može ovisiti o sposobnosti obrambenih mehanizama da se odupru upravo takvim napadima.

Kako bi se osiguralo okruženje svjesno opasnosti koje proizlaze iz njihove široke integracije u sve segmente tehnologije i okruženje koje se pridržava sigurnosnih mjera i oprezno pristupa razvoju velikih jezičnih modela, potrebno je definirati i odgovornosti za sigurnosne propuste u razvoju modela. O temi odgovornosti, potencijalnoj šteti i neželjenim reperkusijama jezičnih modela govore Mittelstadt i sur. (2016) tvrdeći kako je pitanje odgovornosti za štetne posljedice jezičnih modela izuzetno komplicirano. Smatraju da je tomu tako upravo zbog činjenice što u samom procesu razvoja sustava za obradu prirodnog jezika sudjeluje velik broj dionika. Zbog toga autori naglašavaju važnost pravilnog i kvalitetnog pravnog okvira koji će unaprijed definirati odgovornosti i pravne posljedice mogućih pogreški i negativnih efekata koje mogu proizaći iz sustava za obradu prirodnog jezika.

2.2. Metode i modeli obrade prirodnog jezika

Obrada prirodnog jezika predstavlja okosnicu razvoja modernih tehnologija umjetne inteligencije. Kao takva omogućava računalima da u većoj ili manjoj mjeru razumiju osnovne koncepte ljudske komunikacije, interpretiraju značenje ljudskog jezika i reproduciraju sličan ili identičan sadržaj. Prema već ranije spomenutom, metode i modeli korišteni u obradi prirodnog jezika koriste se različitim kombinacijama lingvistike, statističkih tehnika i dubokog učenja. Metode i modeli obrade prirodnog jezika mogu se promatrati kao različite tehnike koje sustavima za obradu prirodnog jezika omogućavaju učinkovitije, brže i preciznije obrađivanje i razumijevanje ljudske komunikacije.

2.2.1. Metode obrade prirodnog jezika

Prije samog specificiranja i objašnjenja različitih modela, potrebno je analizirati po čemu se metode obrade prirodnog jezika razlikuju. Metode se mogu interpretirati i kao različite tehnike i pristupi koji se danas aktivno koriste u obradi prirodnog jezika. Metode su za razliku od modela općenitiji pojmovi, a one mogu koristiti prilikom primjene različitih modela za obradu prirodnog jezika. U nastavku će biti pružen pregled određenih metoda za obradu prirodnog jezika.

Tokenizacija je proces klasifikacije i segmentacije određenog teksta u manje cjeline poput riječi i rečenica (Jurafsky i Martin, 2021), a ona predstavlja neophodan proces koji prethodi procesu

obrade prirodnog jezika. Dakle, tokenizacija je proces kojim se zadani tekst svodi na relativno manje cjeline koje sustavu pomažu sustavu u procesu pripreme obrade prirodnog jezika.

Nadalje, dodatno važan proces koji je potrebno spomenuti prilikom analize metoda obrade prirodnog jezika je lematizacija koja prema Schutze i sur. (2008) označava postupak vraćanja riječi na njihov osnovni oblik što sustavu omogućava dosljednost u jeziku i značajno povećava konciznost u rješavanju zadataka i obradi prirodnog jezika. Također, vrlo sličan, a opet specifičan proces lematizaciji je engl. stemming. Isti autori objašnjavaju ga kao proces jednakog cilja – skraćivanja riječi i svođenje na njezin korijen. Ono što je međutim važno razlikovati između lematizacije i stemminga je metoda skraćivanja. Dok lematizacija predstavlja svođenje na kanonski oblik riječi poput glagolskog infinitiva ili imenice, stemming je pak metoda skraćivanja riječi za sufiks i prefiks. Oba procesa imaju isti učinak, a to je skraćivanje riječi, ali oba u procesu obrade prirodnog jezika imaju potpuno različitu svrhu za sam sustav obrade.

Iz navedenog se također može zaključiti kako su tokenizacija i lematizacija dva vrlo slična pojma. Upravo je zbog toga potrebno u potpunosti razumjeti razliku između tokenizacije i lematizacije. Tokenizacija je segregacija dijelova teksta u njegove manje cjeline, tzv. tokene što predstavlja prvi korak u obradi prirodnog jezika. Proces lematizacije nastupa tek nakon što je tokenizacija gotova. Cilj tokenizacije je podijeliti tekst na lako razumljive cjeline što sustavima značajno olakšava proces obrade jezika. Lematizacija pak svodi riječ na osnovni oblik neovisno o obliku u kojemu se riječ nalazi u inicijalnom tekstu. Svođenje na njen osnovni oblik sustavu pomaže standardizirati tekst.

Engl. Part-of-Speech Tagging – POS je metoda kojom se vrši automatska identifikacija i dodjeljivanje gramatičkih kategorija, poput imenica, glagola i pridjeva, svakom pojedinom izrazu u tekstu, pri čemu se uzimaju u obzir njihova značenja i kontekst u rečenici (Bird i sur., 2009). Dakle, idući korak je definiranje gramatičkih kategorija riječi u tekstu pri čemu se uzima u obzir kontekst u kojemu se određena riječ spominje i relacije s preostalim riječima u tekstu. Ovakvo označavanje pomaže sustavu jasno razlikovati različite kontekste i pružiti kvalitetnu interpretaciju značenja pojedine riječi u rečenici.

Još jedna važna metoda obrade prirodnog jezika je i engl. Named Entity Recognition - NER metoda. Za razliku od prethodne metode koja teži gramatički precizirati kontekst riječi, NER metoda ima značajno važniju svrhu, a to je pridodavanje šireg konteksta i značenja. O NER metodi u svom znanstvenom radu govore Nadeau i Sekine (2007) objašnjavajući prepoznavanje imenovanih entiteta (NER) kao proces identifikacije i kategorizacije specifičnih entiteta unutar

teksta u „unaprijed definirane skupine poput imena ljudi, organizacija, vremenskih izraza, količina, novčanih vrijednosti, postotaka i slično.“ Zaključno, NER metoda omogućava lakše izdvajanje važnih informacija iz velikih tekstova omogućava sustavu raspoznavanje različitih entiteta te njihovih relacija unutar teksta.

Brojne su i druge metode poput parsiranja ili sintaksne analize, analize sentimenta, oblikovanja teme, strojnog prevođenja i ugradnje riječi. Od njih je za kraj potrebno naglasiti metodu ugradnje riječi, engl. word embedding, čija je glavna ideja omogućiti prikaz riječi kao gusto raspoređenih vektora u kontinuiranom vektorskom prostoru, gdje su riječi sličnog značenja smještene blizu jedna drugoj (Levy i Goldberg, 2014). Kako autori navode, ova metoda olakšava računalima da prepoznaju i obrade semantičke odnose među riječima, ali i omogućava učinkovitije i preciznije izvršavanje različitih zadataka obrade prirodnog jezika. Kroz ugradnju riječi, računalni sustavi mogu bolje razumjeti značenje i povezanost riječi, što značajno poboljšava njihovu izvedbu u brojnim aplikacijama.

2.2.2. Modeli obrade prirodnog jezika

Prema već navedenom, modeli obrade prirodnog jezika se značajno razlikuju od metoda. Metode predstavljaju različite tehnike za rješavanje jezičnih izazova prilikom obrade prirodnog jezika. Modeli se mogu promatrati kao sustavi koji implementiraju i kombiniraju različite metode za obradu prirodnog jezika, kreirajući pritom specifične algoritme za postizanje željenih ciljeva. Pokrećući metode, modeli su ti koji sustavima služe za obradu teksta. Pritom je važno naglasiti kako su modeli značajno širi pojam te mogu sadržavati i primjenjivati nekoliko različitih metoda. Broj modela tako se svakim danom povećava uslijed razvoja novih i kompleksnijih algoritama. Do danas su evolucijom razvijeni brojni modeli s različitim stupnjem razvoja koji se kontinuirano unaprjeđuje. U nastavku će biti pružen pregled različitih modela, počevši od onih najranijih i manje razvijenih, sve do novijih, naprednijih i kompleksnijih modela za obradu jezika.

Najraniji i najnerazvijeniji modeli za obradu prirodnog jezika bili su statistički modeli. Manning i Schutze (1999) objašnjavaju ih kao modele čija je polazišna točka hipoteza da je jezik uzročno-posljedična veza različitih događaja pri čemu svaki idući događaj ovisi o prethodnima. Na tragu navedenog, događajima se mogu smatrati riječi u rečenici. U tom kontekstu, statistički modeli pokušavaju predvidjeti nadolazeću riječ u rečenici temeljem prethodnih riječi u rečenici. Za takav pristup, ovakvi modeli koriste se statističkim vjerojatnostima. Autori u nastavku navode konkretne modele koje kategoriziraju kao statističke, a to su: N-gram modeli, Skriveni

Markovljevi modeli i Modeli maksimalne entropije, a ovi se modeli primarno razlikuju prema specifičnom pristupu analizi i razumijevanju vjerojatnosti i obrazaca u strukturi jezika.

Uz statističke, važni su i linearni modeli za obradu prirodnog jezika. Neki od linearnih modela su prema Murphy, K.P. (2012) logistička regresija i stroj potpornih vektora koji prema autoru spadaju u temeljne metode strojnog učenja, a karakteristika im je jednostavnost u procesu klasifikacije i regresije. U ovakvim modelima koristi se linearan pristup analizi ulaznih podataka i njihova povezanost s predviđenim učincima, tj. izlazima. Kada je riječ o klasifikaciji, model tumači kojoj specifičnoj kategoriji određena riječ pripada, dok prilikom regresije model predviđa izlazne vrijednosti. Temeljna specifičnost kod linearnih modela je činjenica da traže jasno relaciju između dostupnih, tj. ulaznih podataka i onih podataka koji se pokušavaju predvidjeti.

Modeli vektorizacije riječi, engl. word embedding modeli, također su jedan od popularnijih modela za obradu prirodnog jezika. Uz GloVe model, najrelevantniji primjer ovakvog modela je Word2Vec model koji u svom radu detaljno analiziraju Mikolov i sur. (2013), objašnjavajući ga kao posebno efikasan prediktivni model koji analizira riječi iz neobrađenog teksta te na temelju njih donosi odluku o sljedećim riječima. Model funkcionira na principu pretvaranja riječi u nizove brojeva, tj. vektore. Pritom, model riječi svrstava u tzv. matematički prostor pri čemu, uzimajući u obzir značenje i semantičku relaciju, riječi sličnog značenja smješta blizu jednu drugoj. Na ovaj način se sustavu omogućava lako razumijevanje povezanosti pojedinih riječi i lakše razumijevanje jezika.

Uz spomenute modele, važno je spomenuti i rekurentne neuronske mreže čijom se analizom bave Goodfellow i sur. (2016) definirajući ih kao posebno dizajniranu vrstu neuronskih mreža koje analiziraju podatke u zadanom slijedu poput rečenice. Takve mreže prema autorima imaju sposobnost pamćenja informacija iz ranijih dijelova tog slijeda što im značajno olakšava i poboljšava razumijevanje konteksta teksta. Rekurentne neuronske mreže zbog ovakvog su mehanizma funkcioniranja za autore ključne u izvršavanju različitih tipova zadataka poput razumijevanja govora, obrade jezika, praćenja trendova s protekom vremena i slično.

Ključnom smatraju činjenicu da mreže ne uzimaju u obzir posljednji ulaz, već i čitavu povijest unesenih podataka što sustavu za obradu pruža dodatnu i puno širu povijesnu perspektivu ulaznih podataka. Ključan pojam pri analizi rekurentnih neuronskih mreža su sekvencijalni podaci koje autori također obrađuju. Sekvencijalne podatke definiraju kao skup različitih vrsta podataka za čije je potpuno razumijevanje konteksta izuzetno važan redoslijed obrade podataka.

Jednostavnije govoreći, rekurentne neuronske mreže svaki novi ulazni podatak usmjeravaju kroz niz već poznatih, povijesno prikupljenih informacija. Na ovaj se način novim ulaznim podacima pridružuje povijesni kontekst pojavljivanja sličnih riječi.

Začetnici naprednije vrste rekurentne neuronske mreže, engl. long short-term memory – LSTM mreže, Hochreiter i Schmidhuber (1997), ovakav model osmišljavaju upravo iz potrebe za osiguravanjem dugotrajnog pamćenja sustava. Autori tumače kako je upravo problem klasičnih rekurentnih neuronskih mreža pamćenje informacija iz ranijih koraka u dugačkim sekvencama. U svom rješenju, LSTM modelu, njihov temelj je upravo dugotrajno pamćenje. Kada je riječ o strukturi mreže, tvrde kako se mreža sastoji od tzv. LSTM ćelija pri čemu se svaka od njih sastoji od tri važna elementa: ulaznih vrata, vrata za zaboravljanje i izlaznih vrata. Na ovaj način mreža kontrolira tijek protjecanja informacija kroz ćeliju. Kvalitetnijim upravljanjem protokom informacija mreži se osigurava da precizno uči i po potrebi zadržava dugoročno važne informacije.

Idući važan model je engl. Transformer model koji predstavlja najnapredniji model obrade prirodnog jezika. Prema Goldbergu (2017), ovaj model za razliku od prethodnih uvodi koncept samopažnje. Samopažnja modelu omogućava sposobnost prioritizacije različitih segmenata ulazne sekvence prema važnosti što značajno poboljšava njegova postignuća. Ovo se postiže kroz paralelnu obradu čitavih sekvenci u jednom tekstu. Točnije, modeli istovremeno i paralelno obrađuju sve riječi u zadanom tekstu, neovisno o njihovom međusobnom odnosu i kontekstu.

Iz engl. Transformer modela su daljnjom evolucijom nastali najpopularniji modeli današnjice. Ti modeli svoje postojanje temelje na arhitekturi transformerskog modela. Prvi je engl. Bidirectional Encoder Representations from Transformers - BERT, dok je drugi, najvažniji za sami kontekst rada, Generative Pre-trained Transformer - GPT.

Radford i sur. (2018) u svom radu, koji je služio kao svojevrsno predstavljanje samog GPT modela javnosti, objašnjavaju model, njegove karakteristike, specifičnosti i inovaciju koju donosi u područje obrade jezika. Autori u uvodu navode kako je temelj za razvoj GPT modela upravo model transformatora. Naglašavaju kako je model obučen na velikoj zbirci tekstualnih podataka, a da je prilagođen za rješavanje specifičnih zadataka što ga čini izuzetno učinkovitim asistentom za generiranje prirodnog jezika i obavljanje različitih zadataka.

Isti istraživački tim poduzeća OpenAI, Radford i sur. (2019), dvije godine nakon inicijalnog predstavljanja GPT modela, predstavlja jednu od ključnih karakteristika novijih verzija

unaprjeđenog modela, jednostranu pažnju. Jednostrana pažnja nameće se kao ključan čimbenik u činjenju novijih verzija GPT modela daleko konkurentnijim od njegovih prethodnih verzija. Autori zaključuju kako je, primjenjujući koncept jednostrane pažnje, fokus modela prilikom obrađivanja i generiranja novog teksta, isključivo na riječima koje je sam model već generirao i napisao. Tako se model koncentrira isključivo na već generirani tekst, a ne i na riječi koje dolaze kasnije.

2.2.3. Važnost kvalitetnih izvora podataka u obradi prirodnog jezika

Dosadašnji temelji u radu naslućuju koliko su sami podaci važni za razvoj obrade prirodnog jezika. Pritom, važno je naglasiti kako su važna oba aspekta podataka – i njihova kvantiteta, ali i kvaliteta. Kvantiteta podataka pruža novijim modelima veću opskrbljenost ažuriranim podacima što im omogućava usklađenost podataka u vremenu, dok kvaliteta podataka osigurava precizan skup ulaznih podataka. Može se reći kako podaci postaju najvrjedniji resurs u nadolazećoj tehnološkoj revoluciji uzrokovanoj pojavom naprednijih koncepata i eksponencijalnim razvojem umjetne inteligencije.

Važnost podataka proizlazi iz činjenice da su alati umjetne inteligencije s funkcijom generativne umjetne inteligencije uvelike temeljeni na velikim jezičnim modelima. Veliki jezični modeli podrazumijevaju velike skupove i količine podataka u procesu treniranja modela. Posljedično, kvaliteta podataka kojima se modeli treniraju značajno utječe na preciznost, pouzdanost i kvalitetu konačnih rezultata koje model pruža. U nastavku su prikazane neke od najvažnijih značajki podataka kao i njihov utjecaj na kvalitetu modela kroz do sada provedena relevantna istraživanja u akademskoj literaturi.

O utjecaju kvalitete podataka na točnost modela govore Phan i sur. (2008) navodeći kako je kvaliteta podataka ključan čimbenik koji osigurava preciznost i efikasnost modela pri čemu kvalitetni podaci smanjuju vjerojatnost generiranja pristranih ili nepotpunih podataka. Zbog toga autori kao glavni zaključak svog istraživanja navode potrebu za treniranjem modela na čistim, točnim i kvalitetno strukturiranim podacima. Kada je riječ o kvantiteti podataka, tvrde kako je za učinkovitost modela poželjno njihovo treniranje na raznolikom skupu podataka što značajno smanjuje utjecaj potencijalnih nepravilnosti.

Kvaliteta podataka ima snažnu korelaciju s pristranošću modela prilikom obrade podataka i generiranja teksta. Ovu korelaciju istražuju Bolukbasi i sur. (2016) navodeći kako lošiji podaci mogu uzrokovati pristranosti modela prilikom obrade i generiranja teksta. To samo po sebi prema autorima nije toliki problem, koliko činjenica da sustavi umjetne inteligencije mogu

dodatno pojačati pristranosti. Dakle, prema autorima je prvenstveni problem treniranje modela na pristranim podacima, a još gora buduća posljedica može biti nastajanje još snažnijih društvenih nejednakosti uzrokovanih pojačavanjem segregacije od samog modela.

Jednako važan čimbenik ključan za treniranje modela na kvalitetnim podacima je zastarjelost podataka i utjecaj neažuriranih podataka na relevantnost i preciznost modela. Zastarjeli podaci dio su istraživačkih pitanja studije Game i sur. (2014) koji proučavaju izazove i barijere s kojima se suočavaju noviji modeli prilikom usklađivanja promjena u podacima kao i metodama za uočavanje i prilagodbu tim promjenama u podacima. Ovo je posebno važno s obzirom na vrlo dinamično podatkovno okruženje koje je podložno konstantnim i kontinuiranim promjenama.

Zbog toga je, prema autorima, u prediktivnoj analitici nužno obratiti pozornost na tzv. „pomak koncepta“ koji odražava promjenjivost podataka i njihovih relacija u modelu kroz protek vremena. Autori također definiraju „postupni pomak, nagle promjene i povratni pomak“. Također, zaključuju kako dugoročna održivost modela ovisi o sposobnosti modela da se uspješno prilagođava pomacima u svrhu održavanja točnosti.

Konačno, za sam kraj analize kvalitete podataka, potrebno je analizirati i ulogu količine podataka te reperkusije kvantitete na samu kvalitetu i preciznost modela za obradu prirodnog jezika. Afirmaciju pozitivne korelacije između kvantitete podataka i preciznosti modela donose Kaplan i sur. (2020). Autori smatraju da, kako se veličina skupa podataka povećava, izvedbe neuronskih jezičnih modela pokazuju kontinuirana poboljšanja, što se jasno očituje kroz logaritamski rast. Ova spoznaja ukazuje na to da veći skupovi podataka mogu značajno doprinijeti povećanju točnosti i sposobnosti generalizacije modela. Iako jedinične koristi od dodatnih podataka postaju sve manje s povećanjem količine podataka, njihova važnost za unapređenje modela ostaje značajna.

2.3. Vrste pristupa strojnom učenju u obradi prirodnog jezika (NLP)

Kako je ranije objašnjeno, strojno učenje predstavlja jednu od temeljnih komponenti umjetne inteligencije. Strojno učenje je posebno važno u segmentu obrade prirodnog jezika. Različite vrste strojnog učenja omogućavaju ranije spomenutim modelima učenje iz podataka i prilagodbu različitim jezičnim zadacima. Postoji nekoliko različitih oblika učenja, a to su: supervizirano, nesupervizirano i polusupervizirano, kao i pojačano učenje te učenje prijenosom. Ove su vrste učenja objašnjene u nastavku rada.

2.3.1. *Supervizirano učenje u obradi prirodnog jezika*

Supervizirano ili nadzirano učenje jedan je od osnovnih i najpopularnijih pristupa strojnom učenju. Mitchell (1997) pod nadziranom učenjem podrazumijeva proces učenja funkcije koja povezuje ulazne podatke s odgovarajućim izlaznim vrijednostima koristeći primjere parova ulaz-izlaz. Tvrdi kako je ovaj pristup najrasprostranjeniji u strojnom učenju i široko se primjenjuje u područjima kao što su prepoznavanje slika, prepoznavanje govora i obrada prirodnog jezika.

O važnosti i napretku koje nadzirano učenje donosi u područje obrade prirodnog jezika govore Vaswani i sur. (2017) tvrdeći kako je strojno učenje značajno evoluiralo uslijed primjene nadziranih modela i razvoja novih modela, među kojima naglašavaju važnost transformatorskih arhitektura. Ove arhitekture prema autorima donose preciznije i prirodnije prijevode s jednog na drugi jezik.

No, postoje i izazovi koje primjena nadziranog učenja donosi. O potencijalnim problemima ove vrste strojnog učenja govore Ratner i sur. (2017) koji kao presudne faktore kod izvedbe modela vide velike količine označenih podataka potrebnih za ovakav razvoj. Objašnjavaju kako prikupljanje velikih količina podataka može biti financijski, ali i vremenski zahtjevno. Govoreći o velikoj količini podataka, potrebno je ponovno spomenuti važnost izazova pristranosti modela.

Govoreći o primjenama nadziranog učenja u obradi prirodnog jezika, valja spomenuti i konkretne primjere i studije slučajeva koji pokazuju važnost doprinosa superviziranog učenja u rješavanju stvarnih problema.

Jedna od ključnih primjena umjetne inteligencije za čovječanstvo, u budućnosti će se ogledati u zdravstvenoj industriji. Uloga prediktivnih modela u zdravstvu će u budućnosti biti od velike koristi u svrhu preventivnog djelovanja i liječenja. O ulozi nadziranog učenja u zdravstvenoj industriji u svom istraživanju pišu Obermeyer i Emanuel (2016) pojašnjavajući kako je primjena superviziranog učenja vidljiva u kreiranju preciznih modela za predviđanje ishoda pacijenata, poput procjene rizika od ponovljenog javljanja bolesti. Tvrde kako se ovakvi modeli temelje na učenju iz detaljnih podataka o pacijentima.

Druga važna industrija je financijska industrija koja kontinuirano teži optimizaciji procesa. Nadzirano učenje prema Khandaniju i sur. (2010) u financijskoj industriji pronalazi svoju važnu ulogu u području kreditnih rizika. Autori navode kako se procjena kreditnog rizika vrši putem

razvijenih i treniranih modela na povijesnim podacima. Ovakvi podaci pružaju detaljan uvid u financijsku stabilnost, ali i predviđaju vjerojatnost neizvršenja obveza pri vraćanju kredita.

U vremenima kada internetska kupovina preuzima primat u potrošačkim navikama, razvoj internetskih trgovina i oglašavanja doveo je i do velikog stupnja primjene superviziranog učenja u ovom području o čemu govore Covington i sur. (2016) gdje nadzirani algoritmi učenja analiziraju kupčeve prethodne interakcije i njegovu povijest kupovine. Na ovaj način modeli mogu uspješnije predvidjeti kupčeve kupovne navike i preferencije što modelu omogućava da krajnjem korisniku pruža kvalitetniji sustav preporuka kroz ciljano oglašavanje.

2.3.2. Nesupervizirano i polusupervizirano učenje u obradi prirodnog jezika

Nenadzirano i polunadzirano učenje predstavljaju jednako važne pristupe u strojnom učenju. Karakteristična im je ograničenost podataka i manjak prethodnog ljudskog nadzora prije same obrade, a samim tim i ograničeni ulaz koji bi trebao služiti kao temelj za zaključivanje modela.

Prema Zhu i Goldbergeru (2009), nenadzirano učenje se odnosi na identifikaciju skrivenih obrazaca i struktura u podacima bez potrebe za korištenjem označenih primjera, dok polunadzirano učenje kombinira označene i neoznačene podatke kako bi spojilo prednosti nadziranih i nenadziranih pristupa učenju, čime se postiže veća preciznost učenja.

Jednostavnije govoreći, temeljna razlika između nadziranog, nenadziranog i polunadziranog učenja je u načinu i procesu učenja i treniranja modela. Pritom, može se zaključiti kako kod autora označenost podataka podrazumijeva povezanost tih podataka s brojnim drugim informacijama što u konačnici modelu pruža zadani kontekst. Može se zaključiti kako prilikom nadziranog učenja model odluke donosi na temelju unaprijed definiranih i naučenih odgovora pri čemu označeni podaci predstavljaju temelj za učenje modela.

Obratno, kod nenadziranog učenja, model nema nikakvo prethodno znanje niti podatkovni ulaz na temelju kojega bi donosio zaključke. Tražeći skrivene obrasce i strukture, model sam kreira odgovore. Iz ovog objašnjenja proizlazi i temeljni izazov nenadziranog učenja o kojemu govore Bengio i sur. (2013), a koji zaključuju kako su glavni izazov kod nenadziranog učenja poteškoće u procjeni kvalitete rezultata koje nastaju upravo zbog činjenice da ne postoje označeni podaci koji bi omogućili direktnu usporedbu i omogućili ocjenu izvedbe modela.

Polunadzirano učenje kombinira oba pristupa strojnom učenju pri čemu kombinira male skupove označenih i velike skupove neoznačenih podataka čime iskorištava puni potencijal oba pristupa (Chapelle i sur., 2009). Ovaj oblik učenja se zbog kombiniranja velikog skupa

neoznačenih podataka, suočava s jednakim izazovom kao i nenadzirano učenje, izazovom kvalitete podataka. Uz navedeno, komplikacije kod polunadziranog učenja mogu stvoriti i metode za kombiniranje označenih i neoznačenih podataka.

Važno je u nastavku spomenuti i područja gdje je primjena nenadziranog i polunadziranog učenja najrelevantnija. Društvene mreže su u prethodna dva desetljeća postala neizostavan dio svakodnevice svakog čovjeka. Digitalni život ljudi na društvenim mrežama posljedično je razvio i monetizacijske modele temeljene na popularnosti o broju pratitelja. Ovaj fenomen proučavaju Paul i Dredze (2014) pri čemu zaključuju kako je nenadzirano učenje idealna metoda za izradu kvalitetnih analiza podataka s društvenih mreža. Navode kako se ova vrsta učenja može koristiti za prepoznavanje ključnih i popularnih tema na temelju velikog skupa dostupnih, ali nestrukturiranih podataka i tekstova.

Digitalno vrijeme donosi i opasnosti u digitalnom okruženju. Kibernetička sigurnost u tom smislu predstavlja područje od velikog značaja u budućnosti kako bi se i privatni, ali i pravni korisnici digitalnih tehnologija maksimalno zaštitili od potencijalnih opasnosti. Polunadzirano učenje u segmentu kibernetičke sigurnosti ima velik značaj, a o njemu zaključke iznosi Sarker (2021) dokazujući kako tehnike polunadziranog učenja doprinose otkrivanju anomalija u različitim sustavima. Sigurnosna unaprjeđenja sustava postižu se trenirajući model kombiniranjem označenih podataka o napadima te paralelnim pružanjem velike količine neoznačenih podataka o normalnim pojavama.

2.3.3. Preostali oblici učenja u obradi prirodnog jezika

Uz već navedene i pojašnjene oblike strojnog učenja, potrebno je spomenuti i dodatne oblike koji se danas koriste. Preostali oblici učenja su specifičniji od nadziranog, nenadziranog i polunadziranog učenja. Njihova važna pogodnost je prilagođenost specifičnim izazovima u analizama i interpretacijama. Upravo su zbog specifičnih primjena danas sve učestaliji u procesima strojnog učenja i treniranju modela za obradu prirodnog jezika. U nastavku su predstavljeni ostali, do sada ne definirani oblici strojnog učenja.

Sutton i Barto (1999) smatraju se utemeljiteljima pojačanog učenja. Autori u svom predstavljanju koncepta pojačano učenje opisuju kao pristup učenju u kojemu agent sam razvija vlastite sposobnosti za donošenje odluka na temelju promatranja i interakcije s okolinom. U kontekstu sustava za obradu prirodnog jezika, može se zaključiti kako bi agent predstavljao model za obradu prirodnog jezika. Kod pojačanog učenja, model ne donosi odluke na temelju unaprijed istreniranog znanja, već postupno testira koji scenariji doprinose maksimizaciji

korisnosti. Model u ovakvom pristupu učenju dobiva povratnu informaciju poput zadovoljstva odgovorom ili ispravnošću prijevoda. Autori ovu povratnu informaciju tumače kao nagradu za samog agenta koji upravo pomoću tih povratnih informacija biva učen. Koristeći povratnu informaciju model osluškuje trenutno stanje okoline i donosi zaključke o najboljem idućem scenariju i radnjama koje treba poduzeti.

Značaj pojačanog učenja posebno je važan u današnjem kontekstu napretka i razvoja umjetne inteligencije, ali i u kontekstu samog diplomskog rada. Sama aplikacija ChatGPT temelji se na arhitekturi različitih i sve novijih modela GPT. Upravo ChatGPT je primjer najraširenijeg konverzijskog modela umjetne inteligencije prilagođenog za fluidan i razumljiv razgovor s krajnjim korisnikom. Pritom je važno naglasiti kako iz istraživačkih radova zaposlenika poduzeća OpenAI, objavljenih na službenim stranicama poduzeća, proizlazi kako su upravo GPT verzije modela dodatno trenirane koristeći pojačano učenje pri čemu sam model koristi povratnu informaciju korisnika za vlastito treniranje što mu omogućava pružanje kvalitetnijih budućih odgovora prilagođenih potrebama krajnjeg korisnika (OpenAI, 2023).

Govoreći o preostalim oblicima, važno je spomenuti još tri važna oblika učenja – induktivno i relacijsko učenje te genetsko programiranje.


Induktivno učenje podrazumijeva proces u kojem model uči generalizirati iz specifičnih primjera kako bi mogao primijeniti naučena pravila na nove, do tog trenutka nepoznate situacije, prepoznajući obrasce iz podataka korištenih za obuku (Mitchell, 1997). Može se zaključiti kako u slučaju induktivnog učenja model iz značajno specifičnijih primjera uspijeva donositi zaključke za znatno složenije situacije, koristeći učene obrasce kao temelj.

Relacijsko učenje, pak, prema Getoor i Taskar (2007) označava pristup strojnom učenju koji se temelji primarno na podatkovnim odnosima. Dakle, individualne karakteristike, značenje i konteksti pojedinih riječi za ovakav su pristup relativno manji, dok je puno važniji odnos tih riječi s preostalim riječima u tekstu ili rečenici. Autori naglašavaju važnost ovakvog pristupa u područjima poput društvenih mreža koja su podložna značajnijoj potrebi za analizom podataka.

3. CHATGPT MODEL

Generativna umjetna inteligencija vrlo je brzim koracima pokazala kako današnja računala u budućnosti mogu dosegnuti čovjekov razvoj te stvarati sadržaj koji može biti jednako kvalitetan ili čak i bolji od onog sadržaja koji sami ljudi mogu proizvesti. Sam ChatGPT kao aplikacija izuzetno je popularizirao područje generativne umjetne inteligencije. O njegovoj važnosti govori njegova popularnost koju je najlakše mjeriti kroz brzinu stjecanja novih korisnika. Kako bi se stekao potpuni dojam o nevjerovatnoj disruptivnosti ovog alata, najbolji način je usporediti brojke koje je ostvario ChatGPT s povijesno najbrže rastućim aplikacijama poput Facebook-a, Instagrama, TikToka i ostalih aplikacija današnjice.

Grafikon 2: Usporedba vremena potrebnog za dostizanje 1 milijuna i 100 milijuna korisnika




Izvor: Izrada autora prema Business of Apps (2024). *ChatGPT Revenue and Usage Statistics* (2024). Preuzeto sa: <https://www.businessofapps.com/data/chatgpt-statistics/>

Dostupni podaci (Grafikon 2) prikazuju kako je ChatGPT ostvario neosporivo najveći i najbrži povijesni rast novih korisnika od trenutka lansiranja same aplikacije. Vidljivo je kako je ChatGPT prvih milijun korisnika stekao u svega prvih mjesec dana, dok je brojku od nevjerovatnih sto milijuna korisnika dosegnuo već mjesec dana nakon, u drugom mjesecu od puštanja u javnost. Usporedbe radi, TikTok je kao najbrže rastuća društvena mreža prvih milijun korisnika dosegnuo također nakon mjesec dana, dok je sto milijuna korisnika dosegnuo tek devet mjeseci nakon lansiranja aplikacije.

3.1. Osnovni koncepti, arhitektura i način funkcioniranja ChatGPT-a

Kako bi se stekao potpuni uvid konteksta i uloge ChatGPT aplikacije u području umjetne inteligencije, potrebno je svrstati ga u kontekst unaprijed definirane terminologije. Kvalitetan temelj za klasifikaciju pruža analiza i pregled britanskih nacionalnih institucija.

Slika 3: Hijerarhijski kontekst ChatGPT-a unutar područja generativne umjetne inteligencije



Izvor: Izrada autora prema Central Digital & Data Office (2024). Generative AI Framework for HMG (HTML). Službena stranica vlade Ujedinjenog Kraljevstva. Preuzeto sa: <https://www.gov.uk/government/publications/generative-ai-framework-for-hmg/generative-ai-framework-for-hmg-html>

Nekoliko je različitih zaključaka i razlika koje Centralni digitalni i podatkovni ured u sklopu britanske vlade razmatra u kontekstu ChatGPT aplikacije (Slika 3). Za početak, hijerarhijski najširi pojam predstavlja generativna umjetna inteligencija koja objedinjuje i temeljne modele, ali i velike jezične modele pa i sam ChatGPT kao najnižu razinu.

Autori temeljne razlike uočavaju u činjenicama da generativnu umjetnu inteligenciju predstavljaju kao oblik strojnog učenja koji koristi velike skupove podataka za proizvodnju različitog sadržaja. U užem smislu promatraju temeljne modele koji imaju općenitiju svrhu, a to je pomoću velikih neuronskih mreža osigurati model koji je primjenjiv za obavljanje širokog spektra zadataka. Dakle, smatraju se temeljnima upravo iz razloga što ne služe ni u koju specifičnu svrhu, već imaju općenitu svrhu služiti kao osnovica za razvoj specifičnih rješenja koja će biti usmjerena na rješavanje specifičnih problema. Dodatno, kao temeljnu razliku između temeljnih i velikih jezičnih modela vide činjenicu da se temeljni modeli mogu bazirati

na različitim oblicima podataka poput tekstualnih, vizualnih i zvučnih, dok se veliki jezični modeli temelje isključivo na podacima tekstualnog oblika. Iz navedenog proizlazi i temeljna svrha velikih jezičnih modela, a to je isključivo što kvalitetnija analiza i interpretacija prirodnog jezika te generiranje podataka tekstualnog oblika.

Ono što autori navode, a što je posebno važno naglasiti u kontekstu samog diplomskog rada je razlika između ChatGPT aplikacije i različitih verzija GPT modela. Aplikacija ChatGPT predstavlja isključivo aplikativno rješenje jednostavnog dizajna, tj. sučelje koje služi za komunikaciju s krajnjim korisnicima, dok je GPT pozadinska tehnologija i model za generiranje sadržaja u aplikaciji. Dakle, aplikacija ChatGPT predstavlja isključivo alat implementacije GPT modela.

Ono što je posebno važno propitkivati u kontekstu budućnosti, a čega se autori u svom pregledu dotiču je činjenica da su ti alati danas uglavnom dostupni putem posebnih poveznica koje korisnika dovode u specijalizirano sučelje same aplikacije temeljene na velikom jezičnom modelu poput GPT-a. Ono što je značajno za promatranje budućeg utjecaja umjetne inteligencije je mogućnost integracije modela u druge softverske alate, internetske stranice i aplikacije. Upravo potencijal integracije ovakvih modela u brojne druge aplikacije i alate daje naslutiti njihov budući značaj.

Na tragu navedenog, današnju poziciju velikih jezičnih modela i samog ChatGPT-a može se promatrati u kontekstu interneta i internetskih trgovina prije trideset godina. Može se samo naslutiti koliko je teško zamislivo u tadašnjim okolnostima bilo predvidjeti budući razvoj interneta i globalni doseg u kojemu je danas gotovo nemoguće zamisliti poduzeće koje ne posjeduje vlastitu internetsku stranicu i maloprodajnu trgovinu koja ne posjeduje vlastitu internetsku trgovinu. Imajući posebice u vidu nevjerojatno brzu prihvaćenost i rast broja korisnika, u slučaju generativne umjetne inteligencije, taj bi period mogao biti i značajno kraći. Zaključno, s obzirom na smjer razvoja civilizacije, može se pretpostaviti kako će u, ne tako dalekoj budućnosti, gotovo svaki čovjek koji posjeduje digitalnu infrastrukturu, svjesno ili nesvjesno, biti korisnik generativne umjetne inteligencije u nekom od oblika, svakodnevno i redovno posjećujući internetske stranice.


Dodatno se referirajući na ranije spomenuto pojačano učenje kao oblik strojnog učenja, integracija velikih jezičnih modela u različite aplikacije doprinosi njihovom snažnijem i bržem učenju, a ujedno rezultira većom preciznošću i značajno većom dodanom vrijednošću samih alata.

Kada je uspostavljena jasna diferencijacija između aplikativnog rješenja ChatGPT i velikog jezičnog modela GPT na kojemu ChatGPT temelji svoje generirane rezultate, potrebno se osvrnuti i na pozadinsku arhitekturu GPT modela. ChatGPT kao dijaloški sustav se oslanja na osnovnu arhitekturu GPT modela čija je temeljna namjena rješavanje složenih zadataka u području obrade prirodnog jezika (Brown i sur., 2020). U tom procesu koristi višeslojnu transformacijsku mrežu pri čemu, obrađujući velike skupove podataka, generira kontekstualno ispravne i točne odgovore.

Radford i sur. (2019) povezuju sam način funkcioniranja i arhitekturu GPT modela s pogodnostima tih karakteristika za krajnjeg korisnika i generirane tekstualne prikaze. Navode kako svaki pojedinačni sloj složene transformacijske arhitekture ima različitu svrhu i funkciju poput mehanizma samopažnje i naprijed usmjerenih transformacije. Koristeći ove mehanizme, sam model dohvaća kontekst svake pojedinačne sekvence u dugim nizovima podataka što mu pruža visoku razinu učinkovitosti.

Govoreći o samom načinu funkcioniranja GPT modela, važno je pružiti i detaljniji prikaz arhitekture modela.

Slika 4: Konceptualni prikaz arhitekture GPT modela



Izvor: Izrada autora prema Lee, M. (2023). A mathematical investigation of hallucination and creativity in GPT models. *Mathematics*, 11(10), 2320.

Dodatno, u skladu s teorijskim pregledom oblika učenja i treniranja modela, važno je spomenuti i važnost učenja modela kroz interakciju s korisnicima. Velik broj korisnika, kao i viša stopa integracije modela kroz različite aplikacije, doprinosi njegovom usavršavanju i pojačanom treniranju. Uz navedeno, kroz širu izloženost modela većem broju dionika, model ne pruža isključivo kontekstualno usklađene odgovore, već osigurava i njihovu jezičnu usklađenost (Floridi i Chiriatti, 2020).

Prema ranije spomenutom, GPT model se temelji na Transformer arhitekturi koja se, koristeći koncept samopažnje, potpuno oslanja na veći broj slojeva pažnje, a koji modelu omogućavaju istovremenu obradu većeg broja različitih sekvenci podataka u usporedbi s prijašnjim tipovima modela za obradu prirodnog jezika poput rekurzivnih neuronskih mreža (Vaswani i sur., 2017).

Prema autorima, prednosti Transformer modela proizlaze iz toga što ovi modeli ne koriste zastarjele metode za obradu prirodnog jezika zbog čega su generalno učinkovitiji i napredniji. Sam koncept i metoda samopažnje može se opisati kao sposobnost modela da istovremeno pregledava čitave rečenice u tekstovima te, na temelju konteksta, razumije značenje svakog pojedinog dijela teksta neovisno o samom redoslijedu riječi u tekstu. Ova diferencijacija u odnosu na prethodne modele predstavlja njegovu ključnu prednost.

Tako, za razliku od rekurentnih neuronskih mreža kao jednog od modela za obradu prirodnog jezika, Transformer model istovremeno analizira i uspoređuje sve riječi u rečenici ili tekstu. Suprotno, usporedbe radi, glavni nedostatak rekurentnih neuronskih mreža je obrada riječi u tekstu prema redoslijedu u tekstu. Dakle, model rekurentnih neuronskih mreža u svom procesuiranju i analizi teksta obrađuje riječi jednu po jednu, što može značajno usporiti sam proces obrade.

Dodatno, kod rekurentnih neuronskih mreža, ali i ostalih, sličnih modela za obradu prirodnog jezika, izazov može predstavljati i duljina sekvenci. Usljed obrade duljih sekvenci, efikasnost i učinkovitost obrade ovakvih modela koji sekvence obrađuju redoslijedom od početka prema kraju teksta, može biti značajno narušena. Problem duljine sekvence proizlazi iz potencijalnih rizika vezanih uz pamćenje dugoročnog znanja i informacija samog modela. Zbog toga Transformer model, kao model istovremene obrade svih riječi u tekstu, predstavlja izuzetan napredak i važan čimbenik u poboljšanju samih modela današnjice poput novijih verzija GPT modela.

U nastavku svog rada, autori detaljno objašnjavaju mehanizme funkcioniranja pažnje s više glava kojeg uspoređuju s čovjekovim načinom razmišljanja prilikom kojega čovjek,

analizirajući pojedine riječi u rečenici, uspoređuje s preostalim, ključnim riječima u rečenici. Ono što je karakteristično za mehanizam pažnje s više glava je da sam Transformer model isto to radi, ali pritom paralelno jednu riječ analizira u kontekstu i odnosu sa svim ostalim riječima u zadanom tekstu. Najvažnija je činjenica da analizu svake riječi i njezinog odnosa s preostalim riječima u rečenici model radi istovremeno.

U nastavku isti autori objašnjavaju i ulogu pozicijskog kodiranja kod razvoja Transformer modela. Navode kako je pozicijsko kodiranje posebno važno u situacijama kada se model trenira na ulaznim podacima koji nisu adekvatno strukturirani u smislene tekstove jasnog značenja. S obzirom na činjenicu da Transformer model predstavlja napredni model arhitekture koji ne koristi ranije metode za redosljednu obradu podataka, u slučaju da model ne obrađuje podatke u određenom redosljedu, a da pritom ti isti podaci nisu adekvatno strukturirani i povezani, tada to postaje velik izazov za model. Autor navodi kako se prilikom pozicijskog kodiranja modelu kroz treniranje daje do znanja koja nestrukturirana riječ se nalazi na kojoj poziciji u rečenici. Obrazloženo se može i potkrijepiti na stvarnoj situaciji. Ukoliko su ulazni podaci modelu riječi poput „pas“, „čovjek“ i „šeta“, model bez redosljedne analize ne zna koja riječ predstavlja subjekt, a koja objekt radnje. Pozicijsko kodiranje služi upravo u te svrhe kako bi njegovi vektori modelu dali jasno do znanja što je u zadanoj rečenici subjekt, što pomoćni glagol, a što objekt radnje te sukladno tome dodijelilo očekivanu poziciju u rečenici.

Dodatno je kod arhitekture GPT modela potrebno spomenuti i normalizaciju slojeva. Normalizacija slojeva čini proces treniranja modela bržim, a konačni proizvod treniranja stabilnijim (Ba, 2016). Temeljem istraživanja autora, može se zaključiti kako normalizacija slojeva predstavlja jedan od ključnih koncepata za ubrzavanje i stabilizaciju samog modela, a ona svodi sve riječi u rečenici na istu vrijednosnu razinu. Vrijednosna razina, pritom, ne podrazumijeva isključivo jezičnu važnost, već numeričku vrijednost pridodanu svakoj od riječi od strane modela prilikom obrade prirodnog jezika.

Autor objašnjava kako se prilikom obrade prirodnog jezika svaka riječ pretvara u niz brojeva, tj. vektore koji za sam model mogu imati različitu važnost. Važnost za model se kreira na temelju njegove percepcije položaja, učestalosti ili konteksta same riječi u tekstu. Na taj način model veznicima i pomoćnim glagolima može pridati manju važnost prilikom analize sekvence. Kroz normalizaciju slojeva, svim se riječima u sekvenci, neovisno o njihovom jezičnom značenju, izjednačava numerička vrijednost unutar sloja. To modelu nalaže ravnopravnu analizu svake pojedine riječi u tekstu.

Konačno, kod analize arhitekture GPT modela, potrebno je analizirati pretreniranje i engl. dropout tehniku. Bašić i sur. (2008) definiraju pretreniranost kao „stanje neuronske mreže u kojem je ista izgubila sposobnost generalizacije te je postala stručnjak za podatke iz skupa za učenje“, dok je engl. dropout tehnika putem koje se „sprječava prekomjerno opremanje modela ispuštanjem određenog broja jedinica tijekom faze obuke“. Dakle, pretreniranost modela se događa u situaciji kada model suviše dobro i kvalitetno uči specifične detalje iz skupa podataka putem kojih je treniran. Na ovaj način dolazi do zagušenosti modela jer se zbog predobrog učenja poznatih podataka, model značajno lošije snalazi s novim ulaznim podacima. *Dropout* je tehnika koja sprječava pretreniranost modela. Ona se provodi kroz namjerno isključivanje jednog dijela neurona u procesu treniranja što model tjera da bolje generalizira bez previše detaljno objašnjenih podataka.

3.2. Povijesni razvoj ChatGPT modela

Osnovu razvoja današnjeg GPT modela predstavljaju ranije definirani i elaborirani Transformer modeli. Upravo Transformer modeli, kroz drugačiji i inovativniji pristup obradi sekvenci, daju GPT modelu one karakteristike koje su mu osigurale najveću razinu pouzdanosti i najširu primjenu od svih danas dostupnih generativnih modela.

Osnovna ideja generativnih modela umjetne inteligencije je kontinuirano unaprjeđivanje njihovih analitičkih sposobnosti. U nastavku je pružen kronološki pregled razvoja novih verzija GPT modela (Grafikon 3).

Grafikon 3: Kronološki prikaz razvoja novih verzija GPT modela



Izvor: Izrada autora

Razvoj novih verzija GPT modela ogledalo je konstantnog unaprjeđenja samog modela i njegovih sposobnosti za kvalitetniju i bržu obradu podataka, tj. prirodnog jezika. Sam koncept funkcioniranja GPT modela predstavljen je u radu *Improving Language Understanding by*

Generative Pre-Training objavljenom na službenim stranicama poduzeća OpenAI 2018. godine. Od 2018. godine do danas su razvijene brojne unaprijeđene verzije GPT modela, a pritom svaki model odražava značajna poboljšanja u smislu izvedbe samog modela pri čemu se poboljšanja u rezultatima modela ogledaju u maksimalnom kvantitativnom potencijalu generiranih podataka, efikasnosti i preciznosti izvedbe i sve kvalitetnijoj obradi i razumijevanju ulaznih sekvenci. Najvažnija karakteristika inicijalnog GPT modela prema istraživačima leži u činjenici da se model arhitekturom razlikuje od prethodnih zbog čega je treniran na širem skupu različitih podataka, a što ga čini univerzalno korisnijim.

Druga verzija, naziva GPT-2, pokrenuta je 2019. godine, a, prema kreatorima napredne verzije, karakterizira ju milijarda i pol parametara s temeljnom karakteristikom i najvećim napretkom vidljivim u segmentu stvaranja koherentnih odlomaka i cjelina (Radford i sur., 2019). Autori po prvi puta spominju nevjerojatan stupanj razvoja samog modela za kojeg tvrde kako je povremeno sposoban generirati tekst koji značajno nadmašuje tekstove kakve bi kreirali sami ljudi što odražava njegovu robusnost i napredak. Također, o stupnju razvoja govore i navodi autora kako novija verzija GPT-2 modela izaziva zabrinutost javnosti za etička pitanja i rizika koji proizlaze iz inovativnijih modela za obradu prirodnog jezika. Kao posljedicu, poduzeće OpenAI je upravo zbog straha i opreza javnosti odgodilo pristup javnosti i pravovremeno objavljivanje modela.

Treća po redu, još naprednija verzija modela pod nazivom GPT-3, puštena je javnosti na korištenje 2020. godine. Napredne značajke novijeg modela ogledaju se ponovno u kvantiteti parametara kojih je u ovoj verziji 175 milijardi (Brown i sur., 2020). O još snažnijoj robusnosti samog modela govori upravo povećanje broja parametara. U usporedbi s prethodnim, GPT-2 modelom koji je imao milijardu i pol parametara, GPT-3 model sadržava nevjerojatnih 175 milijardi parametara. Dakle, GPT-3 ima oko 117 puta više parametara od svoje prethodne, GPT-2 inačice. Ovo dramatično i eksponencijalno povećanje omogućilo je GPT-3 značajno poboljšane performanse u obavljanju širokog spektra jezičnih zadataka.

Autori također dodaju kako se poboljšanja modela odražavaju i na proširenje spektra implementacije samog modela pri čemu se otvaraju dodatna područja primjene u području prijevoda, dijaloških sustava i skraćivanja zadanih ulaznih sekvenci. Dodatno, ovu inačicu modela pojašnjavaju kao značajno fleksibilniju. Njegova fleksibilnost doprinosi tome da model iz male količine podataka može izvlačiti veliku količinu znanja i donositi brojne zaključke. Zbog toga zaključuju da nema više prevelike potrebe za intenzivnim treniranjem samog modela

kako bi generirao uspješne tekstove. Ujedno, bolje snalaženje samog modela u malim skupovima podataka čini ga idealnim za buduće snalaženje u novim područjima primjene.

Međutim, s povećanjem broja parametara se pojavljuje novi izazov koji prema autorima može biti povremeno uočen, a tiče se ranije pojašnjenog koncepta pristranosti modela ili kreiranja pogreški prilikom generiranja tekstova. Tako u fokus budućeg razvoja stavljaju pitanja etike i sigurnosti umjetne inteligencije i njenog razvoja.

Sama aplikacija ChatGPT javno je predstavljena 2022. godine (OpenAI, 2022). U trenutku predstavljanja, aplikacija je temeljena na GPT-3.5 inačici modela. U svom predstavljanju, poduzeće naglašava kako ChatGPT značajno kvalitetnije upravlja kontekstima. Uz navedeno, značajno bolje performanse pokazuje u segmentu dugih sekvenci, smanjujući učestalost nebitnih i ponavljajućih odgovora. Dodatno, referirajući se na rizike i opasnosti spomenute vezano uz GPT-3 verziju modela, naglašava se kako se kroz pojačano učenje i prikupljanje povratnih informacija korisnika, uspješno trenira model i usmjerava ka praćenju smjernica poduzeća. Praćenje smjernica osigurava adekvatno sigurnosno i etičko okruženje.

Konačno, najveći naglasak i pažnju u diplomskom radu treba pridati posljednjoj, najnaprednijoj inačici GPT modela pod nazivom GPT-4. Ova je verzija modela javno objavljena 2023. godine. Nekoliko je ključnih karakteristika koje je izuzetno važno detaljno obraditi u radu, a koje ChatGPT čine najnaprednijim alatom današnjice i potencijalno temeljnom infrastrukturom digitalne budućnosti. Tehničke specifikacije, karakteristike, postignuća i unaprjeđenja jasno su komunicirana od strane poduzeća OpenAI kroz priopćenja i izvješća.


Tehnički izvještaj poduzeća o GPT-4 modelu (OpenAI, 2023) donosi nekoliko ključnih prednosti najnovije verzije modela. Temeljno postignuće u kontekstu GPT-4 verzije je multimodalnost modela. Multimodalnost se odnosi na sposobnost modela da obrađuje različite vrste podataka. Dakle, novija verzija modela nije više isključivo alat za razvoj dijaloških sustava, tj. sustava za generiranje tekstualnih zapisa, već ima mogućnost obrađivati videozapise i audiozapise. Velik naglasak je na proširenju funkcionalnosti koje multimodalnost donosi samom modelu u terminima korisnosti za širu primjenu. Karakteristika multimodalnosti otvara širok spektar novih mogućnosti i primjene ChatGPT-a u brojnim i različitim industrijama.

Analizirajući multimodalnost, može se reći kako ona odražava istinsku disruptivnost tehnologije generativne umjetne inteligencije. Posebno je zanimljivo koliko je još nedavno, u konceptualnom smislu, bilo teško zamisliti scenarije budućnosti u kojima je umjetna inteligencija sposobna pružati rješenja u kreativnoj industriji. Kreativnost je jedna od temeljnih

odlika ljudske vrste. Općenito je popularno razmišljanje kako su kreativne industrije rezervirane za čovjeka kao kreativno biće koje ima sposobnost, na temelju prethodnih znanja, kreirati nova, zanimljiva, šaljiva i višeznačna rješenja. Sudeći prema trenutnom stanju razvoja umjetne inteligencije i dosadašnjoj brzini razvoja i raspršivanja umjetne inteligencije u kreativnoj industriji, može se zaključiti kako je samo pitanje dana kada će računala biti spremna generirati jednaka ili čak i kvalitetnija kreativna rješenja u odnosu na ljude.

Kao i kod svake nove verzije, i kod GPT-4 modela zabilježena su značajna unaprjeđenja u kontekstu operativne efikasnosti i izvedbe modela. Novija verzija je sposobna generirati značajno složenije i koherentnije tekstove, dok se učestalost pogrešaka i halucinacija modela također u velikoj mjeri smanjuje (OpenAI, 2023). Upravo su ovi podaci vidljivi iz analize i izvještaja o točnosti i pouzdanosti GPT-4 modela (Grafikon 4).

Grafikon 4: Rezultati simuliranih ispita i usporedba izvedbe GPT-3.5 i GPT-4 modela



Izvor: OpenAI. (2023). GPT-4 demonstrates improved accuracy and reliability. Preuzeto sa: <https://openai.com/research/gpt-4>

Grafikon predstavlja rezultate istraživačke analize i simuliranog, usporednog ispitivanja rezultata generiranih koristeći različite verzije GPT-3.5 i GPT-4 modela. Cilj istraživačkog tima

je istražiti sposobnosti i performanse različitih verzija modela u obavljanju zadataka različitih ispitnih područja. Rezultati prema ispitnim područjima GPT-3.5 modela su prikazani plavom bojom, a poredani su s lijeva na desno od područja u kojima GPT-3.5 pokazuje lošiju izvedbu prema onim područjima u kojima pokazuje značajno bolje rezultate. Za potrebe provedbe ispitivanja, u obzir su kod usporedbe uzeti GPT-4 kao multimodalni model, sposoban analizirati različite oblike podataka poput teksta, slika, videa i zvučnih zapisa te *GPT-4 (no vision)* koji služi isključivo kao tekstualni model. Međutim, za potrebe analize, obje GPT-4 verzije modela promatraju se kao proizvod naprednog izdanja i istraživanja u odnosu na GPT-3.5.

Može se zaključiti kako je GPT-4 verzija u većini simuliranih područja značajno nadilazi sposobnosti svoje prethodne verzije, GPT-3.5 modela. Ispitni rezultati pokazuju kako se najveće razlike i napredak u izvedbi modela pokazuju na sljedećim ispitima:

- naprednom ispitu matematičkog računa (engl. AP Calculus AB) koji zahtjeva napredna znanja iz diferencijalnog i integralnog računa
- američkom matematičkom natjecanju (engl. AMC 12), najprestižnijem matematičkom natjecanju za srednjoškolce u SAD-u
- kvantitativnom dijelu GRE ispita (engl. GRE Quantitative) na kojemu su najvažniji čimbenici analitika, kritičko razmišljanje, razumijevanje i zaključivanje

Dodatno, valja spomenuti i napredak u područjima primjenjene makroekonomije, mikroekonomije, kemije, statistike, fizike i povijesti.

Iz navedenog se da zaključiti kako su najveća poboljšanja u performansama modela vidljiva na primjeru matematičkih zadataka te analitike i kritičkog razmišljanja s posebnim naglaskom na tehničke ispite što dodatno potvrđuje sve veći potencijal modela u rješavanju kompleksnijih i složenih zadataka.

3.3. Usporedba ChatGPT-a s drugim modelima za obradu prirodnog jezika

Kako se u proteklih nekoliko godina područje obrade prirodnog jezika izuzetno brzo razvija, skupina kompanija zajedno je razvila jedinstvenu mjeru, tj. metriku (engl. benchmark) koja kvantificira napredak modela za obradu prirodnog jezika u rješavanju raznovrsnih zadataka.

Tako je razvijena SuperGLUE (engl. General Language Understanding Evolution - GLUE) metrika koja objedinjuje teške zadatke namijenjene razumijevanju jezika. Kroz primjenu ove metrike, istraživači imaju mogućnost testirati novo razvijene modele, njihove performanse i

rezultate svog razvoja na skupovima teških zadataka. U sklopu iste inicijative, razvijena je i rang lista (engl. leaderboard) unutar koje su redom, prema stupnju razvoja, poredani najsvremeniji modeli sposobni za najefikasnije rješavanje skupa teških zadataka koji su predmetom SuperGLUE ispitivanja. Dakle, na rang listi su izlistani različiti dostupni modeli i poredani prema njihovom ukupnom učinku na testu (Tablica 1).

Tablica 1: Prikaz SuperGLUE rang liste

Poredak	Ime	Model	URL	Rezultat	BoolQ	CB	COPA	MultiRC	ReCoRD	RTE	WiC	WSC	AX-b	AX-g
1	Inspur Cloud	Hairuo		91.4	92.5	96.5/97.6	100	90.5/67.9	94.1/93.2	92.8	76.1	100	64.6	96.1/94.7
2	JDExplore d-team	Vega v2		91.3	90.5	98.6/99.2	99.4	88.2/66.4	94.4/95.0	93.2	77.4	98.6	-0.4	100.0/50.0
3	Liam Fedus	ST-MoE-32B		91.2	92.4	96.9/98.0	99.2	89.6/65.8	95.1/94.4	93.5	77.7	96.6	72.3	96.1/94.1
4	Microsoft Alexander v-team	Turing NLR v5		90.9	92.0	95.9/97.6	98.2	88.4/63.6	96.4/95.9	94.1	77.1	97.3	67.8	93.3/95.5
5	ERNIE Team - Baidu	ERNIE 3.0		90.6	91.9	96.8/99.2	97.4	88.6/63.2	94.7/94.2	93.2	77.4	97.3	68.6	92.7/94.7
6	Yi Tay	PaLM 540B		90.4	91.9	94.4/96.0	99.0	88.7/63.6	94.9/93.3	94.1	77.4	95.9	72.9	95.5/90.4
7	Zirui Wang	T5 + UDG, Single Model (Google Brain)		90.4	91.4	95.8/97.6	98.0	88.3/63.0	95.4/94.1	92.5	77.9	96.6	69.1	92.7/91.9
8	DeBERTa Team - Microsoft	DeBERTa / TuringNLRv4		90.3	90.4	95.7/97.6	98.4	88.2/63.4	94.5/95.0	93.2	77.5	95.9	66.7	93.3/93.8
9	SuperGLUE Human Baselines	SuperGLUE Human Baselines		89.8	89.0	95.8/98.9	100	81.8/51.9	91.7/91.3	93.6	80.0	100	76.6	99.3/99.7
10	T5 Team - Google	T5		89.3	91.2	93.9/96.8	94.8	88.1/63.3	94.1/93.4	92.5	76.9	93.8	65.6	92.7/91.9

Izvor: Izrada autora prema Super Glue (2024) Leaderboard Version: 2.0, Preuzeto sa: <https://super.gluebenchmark.com/leaderboard>

Kod analize rangiranih modela, važno je uočiti deveti rangirani rezultat koji predstavlja SuperGLUE ljudski referentni rezultat (engl. SuperGLUE Human Baselines). Ovi rezultati predstavljaju temelj usporedbe, tj. referentne vrijednosti koje ljudi ostvaruju prilikom rješavanja zadanih zadataka. Cilj je dakle pružiti uvid u efikasnost i performanse modela kroz testiranje i usporedbu rješenja testova s rezultatima koje postižu ljudi. Iako SuperGLUE platforma i rang lista predstavljaju najrelevantnije globalno mjesto za analizu i testiranje novih modela za obradu prirodnog jezika, GPT model do danas nije testiran. Iako je praksa poduzeća koja se bave razvojem ovakvih modela javno objaviti rezultate svojih modela kako bi prikazali

i prezentirali svoj napredak u istraživanju na SuperGLUE ispitivanjima, poduzeće OpenAI do danas to nije učinilo.

Kao i svaka nova disruptivna tehnologija, veliki jezični modeli i dijaloški sustavi za razgovor na bazi umjetne inteligencije, s obzirom na svoj veliki monetizacijski potencijal, nailaze na tržišne izazove prilikom pojavljivanja novih, konkurentnih modela. Najveća tehnološka poduzeća današnjice potpuno usmjeravaju svoje poslovanje u treniranje i razvoj novih, naprednih jezičnih modela s ciljem zauzimanja što većeg tržišnog udjela. U nastavku je prikazana usporedba GPT modela s konkurentskim modelima poput BERT (engl. Bidirectional Encoder Representations from Transformers), T5 (engl. Text-to-Text Transfer Transformer), RoBERTa (engl. Robustly Optimized BERT Pretraining Approach) i Gemini modela.

Kada je riječ o BERT modelu, opis modela, načini funkcioniranja i diferencijacije od ostalih modela opisani su u izvornom radu Devlina i sur. (2019). Iz samog naziva modela može se naslutiti temeljna karakteristika i razlika BERT modela u odnosu na GPT model. BERT model ulazne riječi analizira koristeći dvosmjerni (engl. bidirectional) pristup, dok GPT koristi jednosmjerni pristup. To u praktičnom smislu podrazumijeva simultanu analizu onih riječi koje se nalaze ispred ili iza promatrane riječi u tekstu. Važno je naglasiti kako GPT koristi jednosmjerni pristup u istu svrhu. Tako će GPT za razliku od BERTa koji promatra i analizira riječi prije i poslije promatrane riječi, analizirati riječi redoslijedom s lijeva na desno. Na ovaj način BERT rješava problematiku i ograničenja jednosmjerne obrade prirodnog jezika.

Autori također navode kako se treniranje BERTa vrši modeliranjem maskiranog jezika (engl. masked language model – MLM). Ovim se pristupom određeni postotak riječi u analiziranom tekstu maskira pri čemu model analizira kontekst svih ostalih riječi u cjelovitom tekstu. Ponovno je važno naglasiti kako se i u ovom području GPT značajno razlikuje od BERTa. GPT prilikom analiza i predviđanja nadolazećih riječi analizira kontekst redoslijedom analiziranih prethodnih riječi. Dakle, BERT riječi predviđa nasumično maskirajući određene riječi te kombiniranim razumijevanjem konteksta svih preostalih riječi u danom tekstu. Smatraju kako je ovo temeljna prednost BERT modela u usporedbi s GPT modelom. Autori također naglašavaju da specifičnost procesa predtreniranja uvelike umanjuje potrebu za kompleksnom arhitekturom s ciljem izvršavanja kompleksnih zadataka i tvrde kako BERT pokazuje izvanredne rezultate i na specifičnim zadacima s boljim učinkom izvedbe čak i od specijaliziranih modela za specifična područja.

Kada je riječ o T5 modelu, ključno je nekoliko temeljnih karakteristika koje Raffel i sur. (2020) navode u svom radu. Tvrde kako im tretiranje svakog problema prema principu „tekst u tekst“ značajno pojednostavljuje primjenu modela, izradu ciljeva, mjerenje i definiranje načina obrade. To podrazumijeva pretpostavku o uzimanju ulaznih podataka u tekstualnom obliku, kao i generiranje novih tekstova također u tekstualnom obliku. T5 model je prema autorima također izgrađen na Transformer arhitekturi, no izrađen je sa specifičnim modifikacijama koje mu osiguravaju značajno širu izvedbu u kontekstu zadataka za obradu prirodnog jezika. Također, navode kako je baš poput BERT modela, T5 model također dvosmjernan što ga razlikuje od GPT modela. Navode kako je fokusiranost modela na tekstualne ulaze i izlaze temeljna karakteristika koja modelu omogućava fino podešavanje za različite zadatke uz minimalne potrebe za modifikacijama. Dakle, model ne teži rješavanju specifičnih zadataka, već široj upotrebi. Ujedno, za razliku od GPT-a koji koristi isključivo arhitekturu s dekoderom, T5 koristi kombinaciju modula enkodera i dekodera.

Konačno, svojim učincima i izvedbom Gemini model se nameće kao jedan od ključnih konkurenata GPT modelu o čemu pišu Qi i sur. (2023). Autori u svojoj konkretnoj usporedbi Gemini i GPT modela klasificiraju nekoliko područja učinkovitosti i razlika u izvedbama modela. Navode kako se u kontekstu vizualnih obrada GPT-4 nameće preciznošću i jasnoćom svojih odgovora, dok Gemini pruža cjelovitiji pregled u odgovaranju te kvalitetnije vizualne i slikovite prikaze. Također, naglašavaju kako GPT-4 ima veći memorijski potencijal te mogućnost istovremenog i kontinuiranog unosa nekoliko različitih vizualnih podataka i slika, dok Gemini posjeduje ograničenja u tom segmentu koja ga svode na mogućnost unosa isključivo jedne slike zbog čega je njegova sposobnost memoriranja prethodnih zahtjeva značajno smanjena. Analiza slika je područje u kojemu Gemini pokazuje značajno kvalitetniji pristup. Dodatno, prilikom analiza teksta u slikama, Gemini se ističe kvalitetnijim prepoznavanjem tabličnih podataka, dok GPT-4 kvalitetnije analizira formule. Zbog većih memorijskih kapaciteta, autori vjeruju kako GPT-4 ima značajno veću stvarnu primjenu i mogućnosti implementacije u poslovanju.

Zaključno, može se reći kako se usporedba GPT i Gemini modela može svesti na usporedbu preciznosti GPT-a i opsežnosti te pedantnosti Gemini modela.

4. POSLOVNA PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE NA PRIMJERU CHATGPT-A


Posebno je važno za potrebe rada obratiti pozornost kakav utjecaj će buduća primjena generativne umjetne inteligencije imati na poduzeća, zaposlenike i društvo u cjelini. Ono što je potrebno naglasiti kako je ova tehnologija izuzetno disruptivna i skalabilna. Skalabilnost joj omogućava nevjerojatno brz napredak što je s obzirom da je njena pojava usko vezana i ima ogroman utjecaj na radnu snagu koja potencijalno nije u mogućnosti pratiti ovako brz tehnološki napredak društva.

4.1. Utjecaj te prednosti i nedostaci implementacije ChatGPT-a u poslovanju

Umjetna inteligencija donosi novi oblik tehnološke revolucije za čovječanstvo. Njezin utjecaj u dugom roku zasigurno će utjecati na brzinu razvoja civilizacije i načina na koje čovjek pristupa razvoju svoje svakodnevnice, ali i poslovanja poduzeća.

Prije svega je potrebno obratiti pozornost na mogući budući utjecaj umjetne inteligencije u cjelini na ukupni potencijal proizvodnje globalnih ekonomija. Ovaj se efekt uvođenja umjetne inteligencije u poslovanje poduzeća može prikazati i makroekonomski (Grafikon 5) kroz utjecaj umjetne inteligencije na granicu proizvodnih mogućnosti (GPP).

Grafikon 5: Utjecaj umjetne inteligencije na granicu proizvodnih mogućnosti (GPP)



Izvor: Izrada autora prema Vespignani, J., i Smyth, R. (2024). Artificial intelligence investments reduce risks to critical mineral supply. *Nature Communications*, 15(1), 7304.

Umjetna inteligencija može potencijalno imati velik utjecaj i značaj na pomicanje krivulje granice proizvodnih mogućnosti - GPP udesno (Vespignani i Smyth, 2024). Ova krivulja u teoriji predstavlja maksimalne količine dvaju dobara koje gospodarstvo, ceteris paribus, može proizvesti koristeći sve dostupne resurse i tehnologije. Nekoliko je različitih učinaka koje umjetna inteligencija ima na poslovne i proizvodne procese.


Jedan od učinaka je automatizacija prilikom koje se, donedavno ručno rađeni zadaci, izvršavaju automatski putem računala. U tom smislu, pogodnost automatizacije kroz primjenu umjetne inteligencije ima pozitivan utjecaj na učinkovitost i rada i kapitala pri čemu zaposlenici u poduzećima mogu u kraćem vremenskom roku biti efikasniji i zadane zadatke izvršavati značajno brže ili pak u jednakom vremenskom roku obaviti veći broj zadataka. Posljedično, efekt automatizacije ima pozitivan učinak na povećanje ukupnih proizvodnih kapaciteta poduzeća i gospodarstava. Povećanje ukupnih proizvodnih kapaciteta s jednakom količinom resursa pomiče GPP krivulju udesno.

Dodatno, svaka tehnološka revolucija do sada dovela je do kreiranja novih oblika poslova te proizvoda i usluga koje do uvođenja nove tehnologije nisu postojali. Na ovaj se način razvijaju nova tržišta koja potiču rast proizvodnje u dugom roku. Konačno, umjetna inteligencija teži u potpunosti optimizirati sve dostupne resurse i maksimizirati ukupni proizvodni potencijal.

Na temelju dosadašnjih revolucija i njihovih učinaka, može se pretpostaviti kako će umjetna inteligencija, a samim tim i generativna umjetna inteligencija, u budućnosti imati ogroman utjecaj na produktivnost poduzeća i društva u cjelini. Preostaje analizirati koja je uloga čovjeka u novom, automatiziranom i računalno intelektualnijem okruženju.

Navedeno potvrđuju i rezultati istraživanja poduzeća PWC i njihovog godišnjeg upitnika globalnim izvršnim direktorima koji su analizirani u nastavku (Grafikon 6).


Grafikon 6: Očekivana promjena ka konkurentnijem okruženju



Izvor: Izrada autora prema PwC, (2024): As CEOs reshape business models, GenAI provides the path to growth. Službena stranica PwC Preuzeto sa: <https://www.pwc.com/us/en/library/ceo-survey.html>

Iz navedenih rezultata (Grafikon 6) jasno proizlazi zaključak kako velika većina ispitanika vjeruje da će generativna umjetna inteligencija drastično transformirati poslovne modele poduzeća, povećavajući pritom operativnu učinkovitost. Kako bi poduzeća ostala konkurentna, glavni prioritet ostaje im provedba uspješne digitalne transformacije, stavljajući najveći naglasak na implementaciju rješenja temeljenih na umjetnoj inteligenciji. Direktori očekuju visoku stopu automatizacije rutinskih zadataka što povećava produktivnost njihovih zaposlenika, kvalitetu izvršavanja zadataka i smanjenje troškova za poduzeće. U nastavku su analizirani i ukupni učinci generativne umjetne inteligencije na poduzeća (Grafikon 7).

Grafikon 7: Kako će generativna umjetna inteligencija utjecati na vaše poduzeće ove godine?



Izvor: Izrada autora prema PwC, (2024): As CEOs reshape business models, GenAI provides the path to growth. Službena stranica PwC Preuzeto sa: <https://www.pwc.com/us/en/library/ceo-survey.html>

Analizirajući ukupni utjecaj (Grafikon 7), ispitanici su u velikoj mjeri uvjereni kako se ključ budućeg inoviranja i održavanja konkurentske prednosti nalazi u primjeni umjetne inteligencije. Pritom, ispitanici prepoznaju važnost održavanja ljudskog faktora uz implementaciju AI rješenja, ali smatraju kako umjetna inteligencija može stvoriti nova radna mjesta, jednako kao i ugroziti postojeća, zbog čega postoji velika potreba za dodatnim obrazovanjem i dokvalifikacijom zaposlenika. Iz financijske perspektive, predviđaju velike uštede u troškovima iako naslućuju velika inicijalna ulaganja u razvoj, prilagodbu i integraciju AI rješenja u postojeće sustave.

Dodatno, neki od izazova koje donositelji odluka vide su etičke norme i pitanja, sigurnosni rizici u kontekstu podataka poduzeća, ali i neizvjesnosti oko budućeg regulatornog okvira vezanog uz područje umjetne inteligencije.


No, primjena umjetne inteligencije dovodi i do novih društvenih izazova. Iako su brojne tehnološke revolucije do sada, retrospektivno gledano, doprinosile razvoju čovječanstva i kreiranju novih poslova za ljude, pitanje glasi je li i ovaj puta tako?

Sama ideja umjetne inteligencije i generativnih modela je automatizirati ručne poslove što u velikoj mjeri podrazumijeva zamjenu ljudi koji izvršavaju te poslove. Čak i pod pretpostavkom da umjetna inteligencija društvu donese više novih oblika poslova nego li im oduzme, pitanje je mogu li, i kako, postojeći sustavi obrazovanja osigurati dovoljnu količinu visokoobrazovane radne snage. U teoriji, ljudi bi u cjelini i strateški gledano trebali biti značajno sposobniji od same umjetne inteligencije koja bi u tom slučaju, baš kao i u ovom trenutku, bila produljena ruka čovjeku u izvršavanju operativnih zadataka.

O ovoj temi govori i Schwab (2016) objašnjavajući promjenu čitavih paradigmi u području tehnoloških inovacija, digitalizacije i automatizacije. Autor tumači kako novi, engl. on-demand koncept ekonomije, iz temelja mijenja i koncept zaposlenja pri čemu zaposlenicima pruža puno veću fleksibilnost i odabir da rade kada i odakle žele. No, opasnost novog okruženja prema autoru je vidljiva u smanjenom broju poslova koji zahtijevaju puno radno vrijeme. Uz navedeno, vrlo važan čimbenik koji autor smatra karakterističnim za novi oblik ekonomije je potreba za konstantnom dokvalifikacijom i obrazovanjem radnika. U vremenima kada promjene postaju uistinu brze, današnji zaposlenici moraju biti kontinuirano u trendu s novim digitalnim tehnologijama kako bi se prilagodili zahtjevima poduzeća.

Zbog toga je važno analizirati i kolika je stvarna opasnost od zamjene poslova i automatiziranjem iste koristeći umjetnu inteligenciju i generativne modele (Grafikon 8).

Grafikon 8: Postotak zanimanja koji se u dugom roku mogu automatizirati



Izvor: Izrada autora prema Goldman Sachs (2023) Generative AI could raise global GDP by 7%, Goldman Sachs, službena stranica. Preuzeto sa: <https://www.goldmansachs.com/insights/articles/generative-ai-could-raise-global-gdp-by-7-percent>


Grafikon 8 pokazuje da radni zadaci oko dvije trećine zanimanja ima značajan dio radnih zadataka koji mogu biti djelomično automatizirani uvođenjem umjetne inteligencije. Većina zanimanja ima između 10% i 50% zadataka podložnih automatizaciji, dok se kod malog broja zanimanja čovjekov rad može gotovo potpuno automatizirati (Goldman Sachs, 2023).

U nastavku je pružen pregled konkretnih utjecaja generativne umjetne inteligencije, velikih jezičnih modela pa i samog ChatGPT-a na poslovanje poduzeća u kontekstu povećanja produktivnosti i efikasnosti.

Jednu od najrelevantnijih studija u području utjecaja ChatGPT-a pružaju Noy i Zhang (2023) analizirajući reperkusije na produktivnost 444 visokoobrazovana ispitanika u području profesionalnog pisanja. Nekoliko je ključnih zaključaka koje autori iznose kao proizvod istraživanja. Prvi važan zaključak je da primjena ChatGPT-a doprinosi smanjenju vremena potrebnog za izvršenje zadatka, a ujedno i značajno povećava kvalitetu krajnjeg ishoda. Drugi važan zaključak koji iznose je teza da primjena ChatGPT-a smanjuje jazove i nejednakosti u znanju zaposlenika pozitivno utječući na redistribuciju produktivnosti značajno povećavajući

kapacitete i sposobnosti slabije osposobljenih zaposlenika. Treći važan zaključak autora daje naslutiti kako ChatGPT u stvarnosti zaposlenicima ne koristi kao produljena ruka u izvršavanju dnevnih zadataka, već suprotno, služi potpuno zamijeniti ulogu čovjeka u procesu osmišljavanja novih ideja. Četvrti zaključak autora tiče se psihološkog utjecaja na zaposlenike prilikom korištenja alata generativne umjetne inteligencije. Tvrde kako korištenje alata pozitivno utječe na ispunjenost zaposlenika uslijed povećanja produktivnosti, no istovremeno dovodi do promišljanja o pozitivnim i negativnim posljedicama buduće primjene i razvoja alata za automatizaciju. U nastavku su detaljnije prikazani rezultati i tijek istraživanja (Slika 5).

Slika 5: Utjecaj i efekti na produktivnost radnika



Izvor: Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187-192.

Autori u svom radu produktivnost ispitanika mjere zaradama po minuti, a ključni učinci ispitivanja pruženi su u nastavku. Grafikon (c) prikazuje kako je na drugom zadatku, nakon upoznavanja s ChatGPT alatom, značajno smanjena distribucija vremena potrebna za izvršenje drugog zadatka u usporedbi s kontrolnom skupinom pri čemu je prosječno vrijeme kontrolne skupine iznosilo 27 minuta, dok je vrijeme prosječno vrijeme tretirane skupine smanjeno na 17 minuta što predstavlja izuzetno velik napredak i utjecaj na produktivnost. Dodatno važan prikaz

utjecaja na produktivnost i kvalitetnije izvršavanje zadataka donosi grafikon (d) koji prikazuje utjecaj na kvalitetu konačnog ishoda i rezultata izvršenog zadatka. Iz njega je također jasno vidljiva redistribucija ocjena ostvarenih na prvom i drugom zadatku pri čemu. Zaključno, ispitanici koji su ostvarili lošije rezultate na prvom zadatku, na drugom zadatku su ujedno značajno povećali kvalitetu rezultata prilikom rješavanja drugog zadatka, smanjujući pritom vrijeme potrebno za izvršenje istog. Dodatno, ispitanici koji su i prvi zadatak riješili uspješno, uspješno su zadržali visinu rezultata, također smanjujući postepeno vrijeme potrebno za izvršenje.

4.2. Primjeri područja podložnih automatizaciji poslovanja pomoću ChatGPT

Implementacija i integracija ChatGPT-a u postojeće poslovne procese može dovesti do značajno veće razine operativne efikasnosti poduzeća. No, postoji nekoliko razina na kojima se implementacija ChatGPT-a može provoditi (Slika 6).

Slika 6: Pristupi primjeni alata generativne umjetne inteligencije na primjeru ChatGPT-a



Izvor: Izrada autora prema Korzynski, P., Mazurek, G., Altmann, A., Ejdys, J., Kazlauskaite, R., Paliszkievicz, J., ... & Ziemia, E. (2023). Generative artificial intelligence as a new context for management theories: analysis of ChatGPT. *Central European Management Journal*, 31(1), 3-13.

Prema Korzynskom i sur. (2023), primjeni ChatGPT-a kao alata generativne umjetne inteligencije može se pristupiti na tri razine: strateškoj, funkcionalnoj i administrativnoj razini.

Autori u ovoj podjeli strateškom razinom smatraju razinu odlučivanja u poduzećima gdje ChatGPT može koristiti za donošenje strateških odluka, upravljanje znanjem te analizu organizacijskih podataka. Dakle, u ovoj funkciji ChatGPT može služiti kao potpora ljudskom odlučivanju. Na funkcionalnoj razini ChatGPT percipiraju kao alat za automatizaciju postojećih procesa unutar poduzeća i svojevrsni kanal digitalne transformacije. Na posljednjoj, administrativnoj razini, autori ChatGPT vide kao alat za automatizaciju repetitivnih zadataka na najnižoj, operativnoj razini koju provode zaposlenici individualno.

Kada je riječ o strateškoj razini, autori naglašavaju sposobnost ChatGPT-a da prikuplja, obrađuje, analizira i generira kvalitetno strukturirane i koherentne podatke pružajući tako donositeljima odluka u poduzećima tzv. proceduralnu racionalnost. Naime, objašnjavaju kako ovaj alat služi kao produljena ruka ljudskim kognitivnim ograničenjima.

Drugo područje naglasaka autora je upravljanje znanjem o poduzeću pomoću generativne umjetne inteligencije. Naime, integracijom ChatGPT-a s vlastitim bazama podataka i korporativnim bazama znanja, poduzeća mogu puno lakše, brže i troškovno učinkovito upravljati znanjem vlastitih zaposlenika. Lakši pristup i obrada podataka poduzeća mogu značajno olakšati upravljanje znanjem u poduzeću. Neka od konkretnih područja koja navode pozivajući se na dostupna istraživanja su: oblikovanje tema i sadržaja, pronalaženje sadržaja, rudarenje teksta i podataka, prilagodba u stvaranju personaliziranog edukativnog okruženja i automatskog skraćivanja dokumenata.

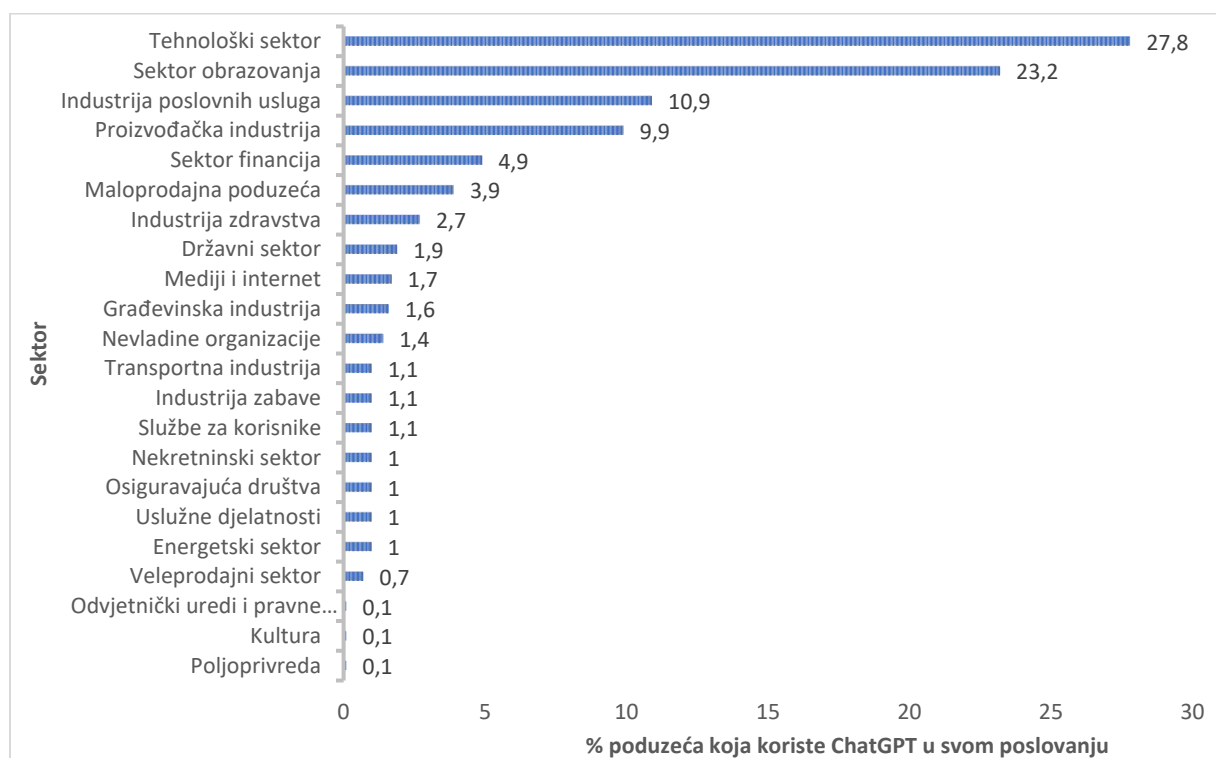
Treća razina je pak najniža, operativna i administrativna razina na kojoj zaposlenici poduzeća proaktivno ili planski koriste ChatGPT u svom svakodnevnom radu kako bi si povećali osobnu produktivnost i skratili vrijeme potrebno za izvršavanje pojedinih zadataka.

Potrebno je naglasiti kako se određena poduzeća, koja si mogu priuštiti ulaganja u digitalnu infrastrukturu, odlučuju na kreiranje vlastitih dijaloških sustava temeljenih na GPT modelu i infrastrukturi ovog velikog jezičnog modela. Poduzeća ovo čine kroz integraciju vlastitih baza podataka s GPT modelom pri čemu ga se prilagođava potrebama zaposlenika poduzeća kako bi odgovarao njihovim potrebama pružajući potrebno kolektivno znanje o poduzeću. Jedan od razloga zbog kojega se poduzeća mogu na ovakav potez je i pitanje privatnosti podataka poduzeća te usklađenosti s internim aktima. Naime, pretpostavljajući da će zaposlenici poduzeća svakako koristiti alate generativne umjetne inteligencije u svom svakodnevnom radu,

poduzeća na ovaj način mogu izbjeći potencijalne opasnosti koje proizlaze iz proizvoljnog korištenja neprovjerenih alternativa.

U nastavku su analizirane mogućnosti i područja u kojima implementacija aplikacije može poslužiti automatizaciji svakodnevnih i ručno izvršavanih zadataka. Može se reći kako je ChatGPT barem djelomično primjenjiv u poslovanju gotovo svakog poduzeća. No, neke industrije su do sada pokazale veću sklonost implementaciji ovog alata, dok je u drugim industrijama razina implementacije još uvijek vrlo niska. Zbog toga je izuzetno važno dubinski analizirati koje industrije i iz kojih razloga imaju visoku razinu primjene umjetne inteligencije i ChatGPT-a kao primjera generativne umjetne inteligencije (Grafikon 9).

Grafikon 9: Prikaz učestalosti implementacije ChatGPT-a u različitim industrijama



Izvor: Izrada autora prema Statista (2024) Amount of companies using ChatGPT in their business function in 2023, by industry. Statista službena stranica. Preuzeto sa: <https://www.statista.com/statistics/1384323/industries-using-chatgpt-in-business/>

Kada je riječ o primjenama ChatGPT-a u pojedinim industrijama (Statista, 2023), ne čudi činjenica da tehnološka poduzeća imaju najveću stopu primjene alata u svom poslovanju. Tehnološka poduzeća su u svojoj prirodi disruptivna, visoko konkurentna i pogonjena inovacijama. Uzimajući u obzir zahtjevnost i kompleksnost te naprednost aplikacija za generativnu umjetnu inteligenciju, smislen je podatak kako je izuzetno velik stupanj

korištenosti ChatGPT-a u obrazovanju. Mlađa populacija ima veću sklonost bržem prihvaćanju novih tehnologija koje im iz temelja mijenjaju svakodnevicu. Treća najvažnija industrija je ona poslovnih usluga. Konzultantska poduzeća u svom djelovanju imaju čestu potrebu izvještavanja i analiza zbog čega visoka stopa implementacije ChatGPT-a može uvelike doprinijeti kvaliteti i brzini rada. Ostale industrije imaju značajno niže stope primjene ChatGPT-a u poslovanju. Ovakva statistika može se tumačiti kao specifičnost pojedinih industrija i visok stupanj ovisnosti o specijaliziranim ljudskim znanjima koja umjetna inteligencija u ovom trenutku nije u mogućnosti nadopuniti ili zamijeniti. Dodatno, postoji i mogućnost manjka svijesti u pojedinim industrijama kao posljedica zatvorenosti i konzervativnog pristupa novim tehnologijama.

Nakon razumijevanja tipova poduzeća i industrija kojima ChatGPT može pomoći u unaprjeđenju poslovanja, potrebno je promotriti koja su to konkretna područja i procesi unutar poduzeća u kojima se generativna umjetna inteligencija može primijeniti. Pregled mogućih područja implementacije ChatGPT-a u poslovanju pruža poduzeće McKinsey (Tablica 2).

Tablica 2: Moguća područja implementacije i učinci implementacije ChatGPT-a u poslovanju

Marketing i prodaja	Operacije	IT/inženjering	Rizici i pravni sektor	Ljudski resursi	Optimizacija zaposlenika
Pisanje marketinških i prodajnih tekstova	Upravljanje korisničkom podrškom	Pisanje programskog koda i dokumentacije	Izrada i pregled pravnih dokumenata	Kreiranje pitanja za regrutacijske intervjue	Optimizacija komunikacije zaposlenika
Stvaranje korisničkih vodiča za proizvode	Identificiranje proizvodnih pogrešaka i anomalija	Automatsko popunjavanje podatkovnih tablica	Sažimanje promjena u regulatornim dokumentima	Interaktivni pristup savjetima za regulativu, zaposlenje i uvjete	Kreiranje poslovnih prezentacija
Analiza povratnih informacija korisnika	Automatizacija i praćenje metrika korisničke podrške	Generiranje sintetičkih podataka – treniranje modela	Odgovaranje na pitanja iz velikih pravnih dokumenata	/	Sažimanje tekstova, prezentacija i zapisnika sa sastanaka
Identifikacija prodajnih prilika, rizika i preporuka za rast i zadržavanje broja kupaca	Identifikacija zanimljivih klauzula i penala kroz komparativnu analizu dokumenata	/	/	/	Pretraga i sažimanje odgovora na često postavljana pitanja vezana uz poduzeće

Optimizacija prodaje pomoću chatbotova	/	/	/	/	Automatizirano računovodstveno sortiranje i vađenje dokumenata
--	---	---	---	---	--

Izvor: Izrada autora prema Chui, M., Dewar, C., & Roberts, R. (2023). Generative AI is here: How tools like ChatGPT could change your business. McKinsey & Company. Preuzeto sa: <https://www.mckinsey.com/~media/mckinsey/business%20functions/quantumblack/our%20insights/generative%20ai%20is%20here%20how%20tools%20like%20chatgpt%20could%20change%20your%20business/generative-ai-is-here-how-tools-like-chatgpt-could-change-your-business.pdf>

U okruženju dinamičnog, globaliziranog i digitalnog tržišta rada te novog koncepta rada od kuće, poduzećima postaje izuzetno zahtjevno zadržati svoje zaposlenike zbog čega područje ljudskih potencijala u posljednjih nekoliko godina doživljava velike promjene i na ovaj segment poslovanja stavlja se sve veći naglasak.

O utjecaju umjetne inteligencije na područje ljudskih potencijala govore Tiwari i sur. (2024) napominjući važnost primjene AI rješenja u selekcijskim procesima. Kvalitetan odabir budućih zaposlenika predstavlja ključ budućeg uspjeha pojedinaca u poduzeću pa i samog poduzeća. Neka od rješenja koje navode su napredni alati za zapošljavanje i alati za analizu prijava za zapošljavanje koji daju prediktivnu funkciju alatima za naprednu analizu kandidata. Pojašnjavaju kako napredna AI rješenja mogu ocjenjivati životopise, vršiti procjene sposobnosti i vještina kandidata te predlagati najprikladnije kandidate za otvorena radna mjesta u poduzeću. Navode kako se korištenjem tih rješenja uklanja subjektivan dojam i pristranost regrutera. No, autori primjenu AI u ljudskim resursima ne vide samo u procesu zapošljavanja, već i u unaprjeđenju iskustva svojih zaposlenika. Tako navode kako alati za upravljanje ljudskim resursima podržani umjetnom inteligencijom poduzećima omogućavaju personalizaciju iskustva zaposlenika, aktivno prateći razvoj tehnološki potkovane i pismene radne snage.

Drugo važno područje poslovanja je marketing. Digitalne strategije rasta postaju sve zahtjevnije i obuhvaćaju nekoliko različitih kanala. Svi podaci prikupljeni kroz različite kanale danas se teže digitizirati, tj. prenijeti u digitalni oblik što omogućava lakše razumijevanje, izradu analiza i definiranje metrika za praćenje dugoročnog napretka.

Primjenom ChatGPT-a u području marketinga istraživački se bave Fraiwan i Khasawneh (2023) govoreći o nekoliko različitih segmenata marketinga s velikim stupnjem potencijalne primjene AI rješenja. Prema autorima, maloprodajne internetske trgovine ChatGPT koriste za

izradu opisa proizvoda i sadržaja za društvene mreže. Ujedno, koristeći integrirana engl. chatbot rješenja, svojim kupcima mogu pružiti jedinstveno i personalizirano iskustvo kupovine i podrške u tom procesu omogućavajući jednostavan i automatiziran pristup traženim ažurnim podacima.

Ujedno, naglašavaju i kako primjena botova u sklopu korisničke podrške može nadmašiti korisnost sučelja na web stranicama poduzeća potičući angažiranost i zadovoljstvo kupaca. Autori navode kako se ChatGPT i ostala rješenja temeljena na umjetnoj inteligenciji sve češće koriste prilikom analize tržišta i kupaca. Tako navode kako je integracija ovakvih rješenja u poslovnu inteligenciju poduzeća (engl. business intelligence - BI) omogućava efektivnu, brzu i troškovno prihvatljivu dubinsku analizu svih dostupnih podataka, predviđanje i uočavanje trendova na tržištu. Dodatno, smatraju kako AI rješenja značajno povećavaju ishode prilikom digitalnog oglašavanja uslijed visokog stupnja personalizacije kampanja i njihove značajne preciznosti.

Dodatno, ChatGPT nudi i brojne druge mogućnosti za skaliranje poslovanja i u kreativnom segmentu marketinga podupirući proces osmišljavanja novih kampanja. U unaprjeđenju digitalnih marketinških i prodajnih procesa može poslužiti za personalizaciju e-mail kampanja te kvalitetnije pozicioniranje na tražilicama, tj. unaprjeđenje engl. search engine optimization – SEO optimizacije.

4.3. Budućnost te izazovi i doprinos ChatGPT-a razvoju umjetne inteligencije

Važno je u kontekstu diplomskog rada obratiti pozornost na digitalnu budućnost značajno promijenjenu pojavom ChatGPT-a, ali i doprinos ChatGPT-a cjelovitom razvoju i popularnosti umjetne inteligencije kao područja.

Etička i pravna razmatranja i perspektivu ChatGPT-a analiziraju Ooi i sur. (2023). Autori smatraju kako zbog činjenice da proces treniranja modela generativne umjetne inteligencije zahtijeva velike skupove podataka za obuku, takav proces može dovesti do rizika. Također, objašnjavaju nekoliko vrsta rizika poput pravnih rizika, ali i rizika vezanih uz izvore i metode nastajanja podataka.


Podaci se uistinu mogu smatrati iznimno važnim resursom današnjice koji na svojoj važnosti tek počinje dobivati. Međutim, može se reći kako današnji veliki jezični modeli podatke

obrađuju značajno brže nego li ljudi te iste podatke prikupljaju. Zbog toga u istraživački fokus sve češće dolazi koncept sintetičkih podataka.

Prema Andrews (2021), sintetički podaci odnose se na informacije generirane kroz računalne simulacije i algoritme kao alternativa stvarnim podacima. Sintetički podaci se virtualno proizvode i ne predstavljaju mjere i nisu prikupljeni u fizičkom svijetu. No, autor naglašava da, iako se sintetički podaci ne prikupljaju u stvarnom svijetu, oni su utemeljeni i odražavaju stvarne, tj. realne podatke u matematičkom ili statističkom smislu.

Može se zaključiti kako je nestašica podataka definitivno veliki izazov za razvoj tehnološki utemeljene budućnosti. U tom smislu, nedostatak podataka može se kompenzirati sintetičkim podacima koji se mogu promatrati kao virtualne izvedenice stvarnih podataka. One u budućnosti mogu poslužiti kao nadogradnja i dodatak stvarni podacima. Sama računala budućnosti bit će sposobna samostalno iznositi zaključke i kroz korelacije kreirati nove podatke i znanja povezujući kontekste različitih, ali dostupnih podataka iz fizičkog svijeta. O važnosti sintetičkih podataka govori i procjena poduzeća Gartner čija skupina analitičara decidirano tvrdi kako će u bliskoj budućnosti, do 2030. godine, sintetički podaci činiti većinu dostupnih podataka pomoću kojih će veliki jezični modeli biti trenirani. Dakle, istraživači očekuju kako će sintetički podaci postati dominantni izvor podataka.

Grafikon 10: Kretanje omjera sintetičkih i stvarnih podataka do 2030. godine



Izvor: Izrada autora prema Ramos, L., & Subramanyam, J. (2021). Maverick Research: Forget About Your Real Data—Synthetic Data Is the Future of AI. Gartner, Inc, Jun. Preuzeto sa: <https://www.gartner.com/en/documents/4002912>

Zbog pojave sintetičkih podataka, smisljena su pitanja koja u svom radu Ooi i sur. (2023) predstavljaju, naglašavajući pritom moguće posljedice proizvedenih rezultata generativnih modela, ali i pitanje odgovornosti u procesu.

Autori se dotiču i točnosti generiranih podataka modela. Tvrde kako veliki jezični modeli imaju tendenciju pružanja uvjerljivih, ali netočnih odgovora. Ovaj koncept nazivaju halucinacijom umjetne inteligencije, a ona može odražavati etičke rizike poput „pristranosti, pravednosti, odgovornosti i transparentnosti“ modela.

Govoreći o zaštiti i privatnosti podataka, autori navode nužan uvjet za funkcioniranje modela iz regulatorne perspektive. Naime, tvrde kako je ključno da model poštuje lokalni zakonski okvir i djeluje potpuno usklađeno regulativi poput ranije spomenute, GDPR regulative u Europskoj Uniji.

5. ZAKLJUČAK

Razvoj generativne umjetne inteligencije uistinu predstavlja prekretnicu za čovječanstvo u tehnološkom smislu. Ta prekretnica će u potpunosti preoblikovati načine na koje ljudi, ali i poduzeća, pristupaju trenutnim procesima i izvršavanju zadataka. Ova će tehnologija i u kratkom roku, ali posebno dugoročno, imati velik utjecaj na povećanje produktivnosti i u kontekstu smanjenja vremena potrebnog za izvršavanje zadataka i iz perspektive povećanja kvalitete ishoda izvršavanja zadataka. Sva poduzeća će, ukoliko žele podići ili zadržati svoju trenutnu konkurentnost, biti primorana primijeniti alate generativne umjetne inteligencije u svom poslovanju. Pritom, značajno su veći učinci ako se implementacija ovakvih alata radi strateški nego li individualno na razini zaposlenika. Zbog toga poduzeća trebaju potražiti načine putem kojih će najbrže i najjednostavnije iskoristiti maksimalni potencijal ove tehnologije. No, u tom procesu trebaju biti izrazito oprezna upravo zbog rizika ove tehnologije poput sigurnosnih rizika za poduzeće, ali i opasnosti za privatnost podataka i mogućih negativnih etičkih reperkusija na poslovanje. U konačnici, može se zaključiti kako, barem u ovom trenutku, umjetna inteligencija zbog svojih nesavršenosti još uvijek nije u mogućnosti u potpunosti zamijeniti čovjeka. U kratkom roku, može se zaključiti kako čovjeka neće zamijeniti umjetna inteligencija, već ljudi koji se njome koriste. U dugom roku, s obzirom na prikazane analize, ovakav scenarij je vrlo realan, stoga je za poduzeća potencijal za optimizaciju poslovnih procesa izuzetno velik. Dodatno, gotovo da ne postoji područje u kojemu primjena generativne umjetne inteligencije nije, barem u određenoj mjeri, moguća. ChatGPT i ostali generativni modeli će oblikovati novu budućnost transformirajući način na koji poduzeća komuniciraju, obrađuju informacije i donose odluke. Njihova je primjena već danas najvidljivija u području marketinških aktivnosti, prodaje i ljudskih resursa. Također, rad detaljizira pogodnosti ChatGPT-a u usporedbi s ostalim velikim jezičnim modelima, prikazujući njegovu superiornost u većini područja. ChatGPT temeljen na modelu GPT-4 u smislu izvedbe nadmašuje konkurentske modele i prethodne verzije GPT modela i u segmentu točnosti, razumijevanja konteksta i prilagodljivosti. Za poslovnu budućnost, ključne aspekte predstavljaju integracije i podaci. Čim veća integracija donosi značajno širu primjenu modela, dok će količina dostupnih podataka u skorijoj budućnosti postati problem. Poduzeća zbog toga moraju aktivno raditi na skaliranju procesa prikupljanja svojih podataka za kvalitetnije donošenje odluka u budućnosti. Važno je da, pritom, poduzeća u svom budućem poslovanju prilikom zapošljavanja moraju razmišljati o kandidatima s visokim stupnjem tehnološke pismenosti, ali i težiti kontinuirano ulagati u svoje zaposlenike i njihova tehnička znanja kako bi ishodi njihova rada bili efektivni.

LITERATURA

1. Andrews, G. (2021) What is synthetic Data. *Blog NVIDIA*, Preuzeto sa: <https://blogs.nvidia.com/blog/what-is-synthetic-data/>
2. Aukstikalnyte, R. (2023). Structured vs. Unstructured Data: Definition, Characteristics, and Comparison. Oxyllabs blog <https://oxyllabs.io/blog/structured-vs-unstructured-data>
3. Ba, J. L. (2016). Layer normalization. 2-14
4. Bašić, B. D., Čupić, M., i Šnajder, J. (2008). Umjetne neuronske mreže. Zagreb: Fakultet elektrotehnike i računarstva, 7-15.
5. Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. MIT Press.
6. Selbst, A. D., & Barocas, S. (2018). The intuitive appeal of explainable machines. *Fordham L. Rev.*, 87, 1085.
7. Beckmann, J. (1787). *Anleitung zur Technologie*. Edition, 3. Publisher: Vandenhoeck Original from, the Bavarian State Library
8. Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
9. Bird, S., Klein, E., & Loper, E. (2009). *Natural language processing with Python: analyzing text with the natural language toolkit*. " O'Reilly Media, Inc."
10. Bolukbasi, T., Chang, K., Zou, J.Y., Saligrama, V., & Kalai, A.T. (2016). Man is to Computer Programmer as Woman is to Homemaker? Debiasing Word Embeddings. *Neural Information Processing Systems*. (pp. 4349-4357).
11. BotPenguin. (n.d.). Technological singularity. BotPenguin. Preuzeto sa: <https://botpenguin.com/glossary/technological-singularity>
12. Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*. 159, 1877-1901
13. Business of Apps (2024). *ChatGPT Revenue and Usage Statistics (2024)*. Preuzeto sa: <https://www.businessofapps.com/data/chatgpt-statistics/>
14. Cambridge Dictionary: intelligence. Preuzeto sa: <https://dictionary.cambridge.org/dictionary/english/intelligence>
15. Cambria, E., & White, B. (2014). Jumping NLP curves: A review of natural language processing research. *IEEE Computational intelligence magazine*, 9(2), 48-57.

16. Central Digital & Data Office (2024). Generative AI Framework for HMG (HTML). Službena stranica vlade Ujedinjenog Kraljevstva. Preuzeto sa: <https://www.gov.uk/government/publications/generative-ai-framework-for-hmg/generative-ai-framework-for-hmg-html>
17. Chapelle, Scholkopf, & Zien (2009). Semi-Supervised Learning. *IEEE Transactions on Neural Networks*, 20(3), 542-542.
18. Chui, M., Dewar, C., & Roberts, R. (2023). Generative AI is here: How tools like ChatGPT could change your business. McKinsey & Company. Preuzeto sa: <https://www.mckinsey.com/~media/mckinsey/business%20functions/quantumblack/our%20insights/generative%20ai%20is%20here%20how%20tools%20like%20chatgpt%20could%20change%20your%20business/generative-ai-is-here-how-tools-like-chatgpt-could-change-your-business.pdf>
19. Courtaud, P. (2023) Understanding Large Language Models and Their Implications: An Interview with OpenAI's CTO. Preuzeto s: <https://www.linkedin.com/pulse/understanding-large-language-models-implications-openais-courtaud-1f> (24.6.2024.)
20. Crawford, K. (2021). Atlas of AI: Power, Politics, and the Planetary Costs of Artificial Intelligence. *Yale University Press*.
21. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Vol 1*, 4171–4186.
22. Dignum, V. (2019). Responsible artificial intelligence: how to develop and use AI in a responsible way (Vol. 2156). Cham: Springer.
23. Dubitzky, W., Wolkenhauer, O., Cho, K. H., & Yokota, H. (Eds.). (2013). Encyclopedia of systems biology (Vol. 402). New York, NY, USA: Springer.
24. ElHousieny, R. (2024). Unveiling the Linguistic Pillars of Natural Language Processing: A Beginner's Guide. Medium.com, <https://ranyel.medium.com/unveiling-the-linguistic-pillars-of-natural-language-processing-a-beginners-guide-de4c1fa55c8b>
25. Enciklopedija.hr: fleksija. Preuzeto sa: <https://www.enciklopedija.hr/clanak/fleksija> [Pristupljeno 26.6.2024.](#)
26. Erickson, B. J., Korfiatis, P., Akkus, Z., & Kline, T. L. (2017). Machine learning for medical imaging. *radiographics*, 37(2), 505-515.

27. European Commission, (2016). General Data Protection Regulation (GDPR) (EU) 2016/679. Preuzeto sa <https://eur-lex.europa.eu/eli/reg/2016/679/oj>
28. European Parliamentary Research Service. (2023). The EU approach to artificial intelligence regulation. European Parliament. Preuzeto sa: [https://www.europarl.europa.eu/RegData/etudes/ATAG/2023/745708/EPRS_ATA\(2023\)745708_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/ATAG/2023/745708/EPRS_ATA(2023)745708_EN.pdf)
29. Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative ai. *Business & Information Systems Engineering*, 66(1), 111-126.
30. Floridi, L., & Chiriatti, M. (2020). GPT-3: Its Nature, Scope, Limits, and Consequences. *Minds and Machines*, 30(4), 681–694.
31. Fraiwan, M., & Khasawneh, N. (2023). A review of chatgpt applications in education, marketing, software engineering, and healthcare: Benefits, drawbacks, and research directions. *Arxiv papers*. Preuzeto sa: <https://arxiv.org/pdf/2305.00237>
32. Gallegos, I. O., Rossi, R. A., Barrow, J., Tanjim, M. M., Kim, S., Deroncourt, F., Yu, T., Zhang, R., & Ahmed, N. K. (2024). Bias and Fairness in Large Language Models: A Survey. *Computational Linguistics*. https://doi.org/10.1162/coli_a_00524
33. Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM computing surveys (CSUR)*, 46(4), 1-37.
34. Getoor, L., & Taskar, B. (2007). Introduction to statistical relational learning. *MIT press*.
35. Goertzel, B. (2014). Artificial general intelligence: concept, state of the art, and future prospects. *Journal of Artificial General Intelligence*, 5(1), 1-48.
36. Goldberg, Y. (2017). Neural network methods for natural language processing. *Synthesis Lectures on Human Language Technologies*, 10(1), 1-309.
37. Goldberg, Y. (2022). Neural network methods for natural language processing. Springer Nature, 63-85.
38. Goldman Sachs (2023) Generative AI could raise global GDP by 7%, Goldman Sachs, službena stranica. Preuzeto sa: <https://www.goldmansachs.com/insights/articles/generative-ai-could-raise-global-gdp-by-7-percent>
39. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. *MIT Press*.
40. Hintze, A. (2016) Understanding the Four Types of AI, from Reactive Robots to Self-Aware Beings. The Conversation. <https://theconversation.com/understanding-the-four-types-of-ai-from-reactive-robots-to-self-aware-beings-67616>

41. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
42. Jin, D., Jin, Z., Zhou, J. T., & Szolovits, P. (2020). Is bert really robust? A strong baseline for natural language attack on text classification and entailment. *In Proceedings of the AAAI conference on artificial intelligence* (Vol. 34, No. 05, pp. 8018-8025).
43. Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing* (3rd ed.). Pearson, (21) 20-23
44. Kaplan, J., McCandlish, S., Henighan, T., Brown, T. B., Chess, B., Child, R., ... & Amodei, D. (2020). Scaling laws for neural language models.
45. Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767-2787.
46. Korzynski, P., Mazurek, G., Altmann, A., Ejdy, J., Kazlauskaitė, R., Paliszkievicz, J., ... & Ziemba, E. (2023). Generative artificial intelligence as a new context for management theories: analysis of ChatGPT. *Central European Management Journal*, 31(1), 3-13.
47. Kurzweil, R. (2005). The singularity is near. In *Ethics and emerging technologies* (393-406).
48. Lee, M. (2023). A mathematical investigation of hallucination and creativity in GPT models. *Mathematics*, 11(10), 2320.
49. Levy, O., & Goldberg, Y. (2014). *Dependency-based word embeddings*. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)* (pp. 302-308).
50. Li, S., Deng, Y. Q., Zhu, Z. L., Hua, H. L., & Tao, Z. Z. (2021). *A Comprehensive Review on Radiomics and Deep Learning for Nasopharyngeal Carcinoma Imaging. Diagnostics* (Basel, Switzerland), 11(9), 1523.
51. Liddy, E.D. 2001. *Natural Language Processing*. In *Encyclopedia of Library and Information Science*, 2nd Edition
52. Manning, C., & Schütze, H. (1999). *Foundations of statistical natural language processing*. MIT press.
53. Manning, C. (2020). *Artificial Intelligence Definitions*. *Institute for HAI, Stanford University*. Preuzeto sa: <https://hai.stanford.edu/sites/default/files/2020-09/AI-Definitions-HAI.pdf>

54. McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, (1955). *AI Magazine*, 27(4), 12.
55. Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM computing surveys (CSUR)*, 54(6), 1-35.
56. Mikolov, T. (2013). Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781.
57. Min, B., Ross, H., Sulem, E., Veyseh, A. P. B., Nguyen, T. H., Sainz, O., ... & Roth, D. (2023). Recent advances in natural language processing via large pre-trained language models: A survey. *ACM Computing Surveys*, 56(2), 1-40.
58. Mitchell, T. M. (1997). *Machine learning*. New York: McGraw-hill. 1(9),11-20.
59. Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2)
60. Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
61. Nadeau, D., & Sekine, S. (2007). A survey of named entity recognition and classification. *Linguisticae Investigationes*, 30(1), 3-26.
62. Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187-192.
63. Obermeyer, Z., & Emanuel, E. J. (2016). Predicting the future—big data, machine learning, and clinical medicine. *New England Journal of Medicine*, 375(13), 1216-1219.
64. Ooi, K. B., Tan, G. W. H., Al-Emran, M., Al-Sharafi, M. A., Capatina, A., Chakraborty, A., ... & Wong, L. W. (2023). The potential of generative artificial intelligence across disciplines: Perspectives and future directions. *Journal of Computer Information Systems*, 1-32.
65. Open AI (2022). Predstavljanje ChatGPT-a. Preuzeto sa: <https://openai.com/index/chatgpt/>
66. Open AI. (2023). ChatGPT: Optimizing Language Models for Dialogue. OpenAI. Preuzeto sa: <https://openai.com/research/chatgpt>
67. OpenAI. (2023). GPT-4 Technical Report. Preuzeto sa: <https://openai.com/research/gpt-4>
68. OpenAI. (2023). GPT-4 demonstrates improved accuracy and reliability. Preuzeto sa: <https://openai.com/research/gpt-4>
69. Open AI. (2024). ChatGPT <https://chat.openai.com/chat>

70. Paul, M. J., & Dredze, M. (2014). Discovering health topics in social media using topic models. *PloS one*, 9(8),
71. Phan, X. H., Nguyen, L. M., & Horiguchi, S. (2008). Learning to classify short and sparse text & web with hidden topics from large-scale data collections. *In Proceedings of the 17th international conference on World Wide Web* (pp. 91-100).
72. PwC, (2024): As CEOs reshape business models, GenAI provides the path to growth. Službena stranica PwC Preuzeto sa: <https://www.pwc.com/us/en/library/ceo-survey.html>
73. Qi, Z., Fang, Y., Zhang, M., Sun, Z., Wu, T., Liu, Z., ... & Zhao, H. (2023). Gemini vs GPT-4V: A Preliminary Comparison and Combination of Vision-Language Models Through Qualitative Cases. *Arxiv papers*. Preuzeto sa: <https://arxiv.org/abs/2312.15011>
74. Radev, D. R., & Mihalcea, R. (2008). Networks and natural language processing. *AI magazine*, 29(3), 16-16.
75. Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving Language Understanding by Generative Pre-Training. OpenAI.
76. Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019). Language models are unsupervised multitask learners. OpenAI blog, 1(8), 9.
77. Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W., & Liu, P. J. (2020). Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer. *Journal of Machine Learning Research*, 21(140), 1-67.
78. Ramos, L., & Subramanyam, J. (2021). Maverick Research: Forget About Your Real Data—Synthetic Data Is the Future of AI. *Gartner, Inc, Jun*. Preuzeto sa: <https://www.gartner.com/en/documents/4002912>
79. Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P., & Green, R. (2019). Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods. *Academic pathology*, 6
80. Ratner, A.J., Bach, S.H., Ehrenberg, H.R., Fries, J.A., Wu, S., & Ré, C. (2017). Snorkel: Rapid Training Data Creation with Weak Supervision. Proceedings of the VLDB Endowment. *International Conference on Very Large Data Bases*, 11 (3), 269-282.
81. Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 160.
82. Schütze, H., Manning, C. D., & Raghavan, P. (2008). Introduction to information retrieval (Vol. 39, pp. 234-265). Cambridge: Cambridge University Press.
83. Schwab, K. (2016). The Fourth Industrial Revolution. Crown Business. Vol 1, 92-97

84. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
85. Statista (2024) Amount of companies using ChatGPT in their business function in 2023, by industry. Statista službena stranica. Preuzeto sa: <https://www.statista.com/statistics/1384323/industries-using-chatgpt-in-business/>
86. Super Glue (2024) Leaderboard Version: 2.0, Preuzeto sa: <https://super.gluebenchmark.com/leaderboard>
87. Sutton, R. S., & Barto, A. G. (1999). Reinforcement learning: An introduction. *Robotica*, 17(2), 229-235.
88. Taylor, M. E., Kuhlmann, G., & Stone, P. (2008). Transfer learning and intelligence: an argument and approach. *Frontiers in artificial intelligence and applications*, 171, 326.
89. Thomas, H. (2009). Introduction to algorithms. *MIT Press*
90. Tiwari, R. (2024). The Impact of Artificial Intelligence in the Workplace and its Effect on the Digital Wellbeing of Employees. *International Journal Of Progressive Research In Engineering Management And Science (IJPREAMS)*, Vol 4, (6) 2422-2427
91. Vaswani, A., Shazeer, N.M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L., & Polosukhin, I. (2017). Attention is All you Need. *Neural Information Processing Systems*.
92. Verspoor, K. M., & Cohen, K. B. (2013). *Natural language processing*. In S. M. Brown, & R. B. Altman (Eds.), *Biocomputing 2013* (pp. 154-155). World Scientific. https://doi.org/10.1007/978-1-4419-9863-7_158
93. Vespignani, J., & Smyth, R. (2024). Artificial intelligence investments reduce risks to critical mineral supply. *Nature Communications*, 15(1), 7304.
94. Watson, D. P. & Scheidt, D. H. (2005). *Autonomous systems*. Johns Hopkins APL technical digest, 26(4), 368-376.
95. Zhou, X., Li, C., Rahaman, M. M., Yao, Y., Ai, S., Sun, C., ... & Teng, Y. (2020). A comprehensive review for breast histopathology image analysis using classical and deep neural networks. *IEEE Access*, 8, 90931-90956.
96. Zhu, X., & Goldberg, A. B. (2009). Introduction to Semi-Supervised Learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 3(1), 1–130.

POPIS SLIKA

Slika 1: Hijerarhijska segmentacija područja umjetne inteligencije	7
Slika 2: Klasifikacija ChatGPT-a u domenu uske umjetne inteligencije	11
Slika 3: Hijerarhijski kontekst ChatGPT-a unutar područja generativne umjetne inteligencije	32
Slika 4: Konceptualni prikaz arhitekture GPT modela	34
Slika 5: Utjecaj i efekti na produktivnost radnika	50
Slika 6: Pristupi primjeni alata generativne umjetne inteligencije na primjeru ChatGPT-a	51

POPIS GRAFIKONA

Grafikon 1: Prikaz koncepta tehnološke singularnosti	10
Grafikon 2: Usporedba vremena potrebnog za dostizanje 1 milijuna i 100 milijuna korisnika	31
Grafikon 3: Kronološki prikaz razvoja novih verzija GPT modela	37
Grafikon 4: Rezultati simuliranih ispita i usporedba izvedbe GPT-3.5 i GPT-4 modela	40
Grafikon 5: Utjecaj umjetne inteligencije na granicu proizvodnih mogućnosti (GPP)	45
Grafikon 6: Očekivana promjena ka konkurentnijem okruženju	47
Grafikon 7: Kako će generativna umjetna inteligencija utjecati na vaše poduzeće ove godine?	47
Grafikon 8: Postotak zanimanja koji se u dugom roku mogu automatizirati	49
Grafikon 9: Prikaz učestalosti implementacije ChatGPT-a u različitim industrijama	53
Grafikon 10: Kretanje omjera sintetičkih i stvarnih podataka do 2030. godine	57

POPIS TABLICA

Tablica 1: Prikaz SuperGLUE rang liste	42
Tablica 2: Moguća područja implementacije i učinci implementacije ChatGPT-a u poslovanju	54

ŽIVOTOPIS



Državljanstvo: hrvatsko i američko



+385 (0)98 996 7828



lekodomagoj1@gmail.com



Josipa Jurja Strossmayera 232
31 000 Osijek

OBRAZOVANJE

Ekonomski fakultet Sveučilišta u Zagrebu

- Sveučilišni integrirani prijediplomski i diplomski studij Poslovna ekonomija
Diplomski studij Menadžerska informatika
 - upravljanje poslovnim procesima
 - robotska automatizacija procesa
 - osnove baza podataka

Akademске nagrade za društvene projekte

- 1x Posebna Dekanova nagrada
- 2x Posebna Rektorova nagrada

JEZICI

- engleski (C1) --> CEFR certifikat
- njemački (B2/C1) --> DSD certifikat

VJEŠTINE

- pretraga i generiranje klijenata
- struganje podataka
- inbound i outbound marketing
- certificirani Hubspot CRM specijalist
 - Marketing, Sales i Operations hub
- upravljanje klijentima
- marketinška i prodajna automatizacija
- Microsoft Office 365, SAP, PowerBI, Copilot profesionalni korisnik
- višekanalna direktna prodaja
 - LinkedIn, e-mail prodajna automatizacija
- prodajne operacije, analitika i izvještavanje
- razvoj i skaliranje proizvoda
- strast prema novim tehnologijama i softverima

DOMAGOJ LEKO

ISKUSTVO

Medtronic Adriatic d.o.o. (2023 - 2024) --> globalna MedTech kompanija Zagreb - Hrvatska (hybrid)

Sales Operations Intern

- unaprjeđenje operativne i prihodovne efikasnosti u CEMA regiji
- napredno korištenje PowerBI, SAP, Salesforce, Copilot i SalesLofta
- digitalizacija, digitalna transformacija i digitalno usvajanje
- poslovna prognostika prihoda i potražnje za proizvodima te analiza tržišta
- menadžment pokretanja i razvoja proizvoda i novih tržišta
- razvoj marketinških strategija za različite poslovne segmente
- razvoj suradnje različitih funkcijskih timova i optimizacija procesa

Degordian d.o.o. (2021 - 2023) --> digitalna agencija

Zagreb - Hrvatska (hybrid)

Business Development Assistant, Performance marketing team

- podrška u razvoju interne strategije rasta agencije na regionalnom i stranim (primarno SAD) tržištima
- samostalan razvoj integrirane usluge marketinške i prodajne automatizacije kao koncepta B2B prodaje za klijente

UPBORE GMBH (2020 - 2021) --> SaaS kompanija, građevinska industrija Zagreb - Hrvatska, Berlin - Njemačka (hybrid)

Sales Development Assistant

- upravljanje prodajnim kampanjama u CEE, DACH i UK regijama
- zadužen za prodajne kampanje, pripremu prodajnih materijala, izradu i prezentiranje sadržaja potencijalnim klijentima, prezentacije softvera
- razvoj novih prodajnih kanala

CJELOŽIVOTNO OBRAZOVANJE

Debatni klub EFZG (2016 - 2020)

Ekonomski fakultet u Zagrebu

Predsjednik

- upravljanje 60 članova na 12 projekata i u 5 funkcijskih timova
 - PR&Marketing, Sales, Project Management, HR i Debate team
- financijsko upravljanje pravnim tijelom, predaja financijskih izvještaja, sklapanje sporazuma s partnerima iz javnog i privatnog sektora, prikupljanje financijskih sredstava, pravni poslovi

Studentski zbor Sveučilišta u Zagrebu (2019 - 2020)

Sveučilište u Zagrebu

Član Predsjedništva SZZG i Potpredsjednik SZEZFG

Poslovna akademija Inga Lalić

- digitalni marketing, upravljanje i vođenje tima, poslovne strategije i upravljanje ciljevima, efikasne prodajne strategije

Coca-Colina podrška mladima