

Razvoj, konfiguracija i primjena ChatGPT-a

Drenjančević, Megi

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Graphic Arts / Sveučilište u Zagrebu, Grafički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:216:231597>

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

Download date / Datum preuzimanja: **2025-02-10**



Repository / Repozitorij:

[Faculty of Graphic Arts Repository](#)



SVEUČILIŠTE U ZAGREBU

GRAFIČKI FAKULTET

ZAVRŠNI RAD

Megi Drenjančević



Sveučilište u Zagrebu
Grafčki fakultet

Smjer: Tehničko-tehnološki

ZAVRŠNI RAD

RAZVOJ, KONFIGURACIJA I PRIMJENA CHATGPT-A

Mentor:

Doc.dr.sc. Diana Bratić

Student:

Megi Drenjančević

Zagreb, 2023

SVEUČILIŠTE U ZAGREBU
GRAFIČKI FAKULTET
Getaldićeva 2
Zagreb, 11. 9. 2023.

Temeljem podnijetog zahtjeva za prijavu teme završnog rada izdaje se

RJEŠENJE

kojim se studentu/ici Megi Drenjančević, JMBAG 0128066418, sukladno čl. 5. st. 5. Pravilnika o izradi i obrani završnog rada od 13.02.2012. godine, odobrava izrada završnog rada, pod naslovom: Razvoj, konfiguracija i primjena ChatGPT-a, pod mentorstvom doc. dr. sc. Diane Bratić.

Sukladno čl. 9. st. 1. Pravilnika o izradi i obrani završnog rada od 13.02.2012. godine, Povjerenstvo za nastavu, završne i diplomske ispite predložilo je ispitno Povjerenstvo kako slijedi:

1. izv. prof. dr. sc. Bates Irena, predsjednik/ica
2. doc. dr. sc. Bratić Diana, mentor/ica
3. izv. prof. dr. sc. Pasanec Preprotić Suzana, član/ica



SAŽETAK

Ovaj završni rad je pregledni rad o razvoju, konfiguraciji i primjeni ChatGPT-a. Cilj rada bio je opisati razvoj, generacije mogućnosti i konfiguracije ChatGPT-a. ChatGPT prvenstveno je *chatbot*. *Chatbot* je računalni program čija je glavna funkcija simulacija sugovornika u razgovoru s korisnikom. Razvoj *chatbotova* započinje u 20.stoljeću i ide od ELIZE do modernih inteligentnih osobnih pomoćnika. *Chatbotovi* se mogu podijeliti u više kategorija, ali najbitnija je ona u kojoj se dijele na one koji koriste tehnologiju usklađivanja uzoraka prilikom generiranja odgovora te one koji se koriste strojnim učenjem u koju pripada ChatGPT. ChatGPT napredna je inačica GPT-3 koja je posebno stvorena za konverzacijsku umjetnu inteligenciju. On stvara dijaloge korištenjem prirodnog jezika te pruža poboljšane odgovore na različita pitanja. Razvoj ChatGPT-a započeo je nastankom OpenAI organizacije koja je posvećena razvoju umjetne inteligencije. Posljednja verzija ChatGPT-a je GPT-4. ChatGPT koristi se tehnologijom prethodno obučenog jezičnog modela, ICL-a, lanca misli, finog podešavanja te podržanog učenja. Zbog mogućnosti finog podešavanja ChatGPT može se primijeniti u raznoraznim industrijama, od medicine do programiranja.

Ključne riječi: chatbot, ChatGPT, strojno učenje, NLP

SADRŽAJ

1. UVOD	1
2. POVIJEST CHATBOTOVA	2
2.1. Funkcije chatbota	2
2.2. Turingov test	2
2.3. ELIZA	3
2.4. Parry	4
2.5. Jabberwacky	5
2.6. Alice	5
2.7. Chatbotovi kao inteligentni osobni pomoćnici	6
3. KONFIGURACIJA	8
3.1. Kategorije chatbotova	8
3.2. Usklađivanje uzoraka	10
3.2.1. AIML (eng. Artificial Intelligence Markup Language)	10
3.2.2. RiveScript	12
3.2.3. Chatscript	12
3.3. Strojno učenje	13
3.3.1. Obrada prirodnog jezika (eng. Natural Language Processing)	13
3.3.2. NLU (eng. Natural Language Understanding)	14
3.3.3. NLG (eng. Natural Language Generation)	15
4. CHATGPT	16
4.1. Povijest ChatGPT-a	16
4.1.1. OpenAI	16
4.1.2. GPT-1	17
4.1.3. GPT-2	17
4.1.4. GPT-3	17

4.1.5. <i>InstructGPT</i>	18
4.1.6. <i>ChatGPT</i>	18
4.1.7. <i>GPT-4</i>	18
4.2. Tehnologija iza ChatGPT-a	18
4.2.1. <i>Prethodno obučeni jezični model</i>	18
4.2.2. <i>ICL (eng. In-Context Learning)</i>	19
4.2.3. <i>Podržano učenje (eng. Reinforcement Learning From Human Feedback)</i>	20
4.3. Primjena ChatGPT-a.....	21
5. ZAKLJUČAK	25
6. LITERATURA.....	26
POPIS SLIKA	29

1. UVOD

U posljednji deset godina tehnologija se ubrzano razvila. Pojam koji se sve češće koristi u vidu napretka tehnologije je umjetna inteligencija čija je primarna funkcija olakšavanje životne svakodnevnice oponašanjem ljudi. Utjecajem umjetne inteligencije promijenjen je način na koji oblikujemo i vrednujemo napredne aplikacije i uređaje za svakodnevne aktivnosti. *Chatbotovi* su postali dio našeg svakidašnjeg života. Primarno se koriste u korisničkoj podršci te kao inteligentni osobni pomoćnici. ChatGPT se izdvaja kao jedan od najnaprednijih *chatbotova* danas. Njegova tehnologija se pomoću finog podešavanja može primijeniti na velik broj industrija koje variraju od zdravstva do obrazovanja.

Cilj ovog preglednog rada je pobliže objasniti djelovanje *chatbotova* te njihov doprinos u razvoju ChatGPT-a. ChatGPT je kompleksan *chatbot* koji se koristi tehnologijama prethodno razvijenih *chatbotova* za unapređenje svog software-a.

Struktura rada podijeljena je na četiri dijela od kojih je prvi uvod u rad. Drugo poglavlje daje definiciju *chatbotova* te objašnjava njihove funkcije. Također opisuje povijesni razvoj *chatbotova* od ELIZE do modernih inteligentnih osobnih pomoćnika. Time daje uvid u važnost kontinuiranog razvoja. U prošlosti je fokus bio na imitaciji ljudskih razgovora i oponašanju različitih ljudskih osobina kao npr. paranoja, dok je danas fokus na rješavanju zadanih problema i generiranju različitih rješenja na bazi unaprijed naučenih podataka. Treće poglavlje objašnjava podjelu te tehnologiju iza *chatbotova*. *Chatbotovi* se prema tehnologiji koju koriste za generiranje odgovora mogu podijeliti na one koji koriste usklađivanje uzoraka te one koji se koriste tehnikom strojnog učenja. Chatbotovi koji koriste usklađivanje uzoraka moraju pratiti unaprijed zadana pravila koje je zadao programer. Oni nisu u mogućnosti procesirati zadatke koji se nalaze u njihovoj bazi zadataka, nego na takve upite odgovaraju sa unaprijed definiranim rješenjima koja nisu nužno odgovor na postavljeno pitanje. *Chatbotovi* koji se temelje na strojnom učenju unaprijed se uče na velikim bazama podataka i nisu vezani uz određene domene znanja. Oni mogu dati odgovore na pitanja iz bilo koje domene. U četvrtom poglavlju se definira što je ChatGPT, koja je tehnologija korištena za njegov razvoj te gdje se sve ta tehnologija može primijeniti.

2. POVIJEST CHATBOTOVA

Chatbot je računalni program čija je glavna funkcija simulacija sugovornika u razgovoru s korisnikom [1]. Chatbotovi su se kroz povijest koristili kako bi olakšali korisniku pronalaženje informacija, za obavljanje zadataka ili bi ih korisnici koristili kako bi popunili manjak socijalne interakcije s drugim ljudima.

2.1. Funkcije chatbota

Funkcije *chatbotova* se mogu podijeliti na sljedeći način:

- a) Dijaloški agent: osigurava funkciju razumijevanja što znači da mora biti u mogućnosti shvatiti problem korisnika. Nužno je da sustav za pomoć ima opciju tekstualnog unosa (usmeni unos je opcionalan) jer to omogućuje korisniku da unese zahtjev za pomoć. Također je neophodno da agent ima sposobnost analize tih zahtjeva pomoću alata za obradu prirodnog jezika (eng. *Natural Language Processing - NLP*) kako bi se prirodni zahtjevi pretvorili u formalne [2].
- b) Racionalni agent: pruža funkciju kompetentnosti. Za obradu formalnih zahtjeva za pomoć sustav mora posjedovati dinamički simbolički prikaz strukture i rada softverske komponente odgovorne za pružanje pomoći. Također, mora imati mogućnost provedbe heurističkog razmišljanja kako bi adekvatno odgovorio na zahtjeve korisnika [2].
- c) Utjelovljeni agent: pruža funkciju prisutnosti. U prošlosti se ova funkcija smatrala izbornom, ali se pokazalo da osjećaj prisutnosti uspostavlja odnos povjerenja s korisnikom [2]. Zbog tog su razloga čak i najraniji *chatbotovi* imali ljudska imena (ELIZA, ALICE, CHARLIE). Današnji razvojni programeri usmjeravaju se na upotrebu jezičnih trikova kako bi oblikovali osobnost *chatbotova* s ciljem stvaranja povjerenja s korisnikom i ostavljanja dojma kao da komuniciraju s utjelovljenim odnosno stvarnim agentom [3].

2.2. Turingov test

Turingov test je test za procjenu inteligencije stroja. Osmislio ga je Alan Turing 1950.godine u svom radu "Računalno strojarstvo i inteligencija (eng. *Computing machinery and intelligence*) koji je objavljen u časopisu *Mind*. U tom radu Turing

postavlja pitanje: “Mogu li strojevi razmišljati? ”. Kako bi odgovorio na to pitanje navodi da prvo treba definirati riječi stroj i razmišljanje. Umjesto definicije riječi predlaže Igru imitacije kao rješenje. Igra imitacije je test kojemu je krajnji cilj otkriti tko je stroj, a tko čovjek. Sastoji se od dvije “osobe” A i B od kojih je jedna stroj, a druga čovjek te ispitivača koji je fizički odvojen. Primarni zadatak ispitivača je postavljanjem pitanja zaključiti tko je stroj, a tko čovjek. Ako ispitivač ne može na temelju odgovora točno razlikovati stroj od čovjeka, smatra se da je stroj prošao Turingov test [4].

Q: Please write me a sonnet on the subject of the Forth Bridge.

A: Count me out on this one. I never could write poetry.

Q: Add 34957 to 70764

A: (Pause about 30 seconds and then give as answer) 105621.

Q: Do you play chess?

A: Yes.

Q: I have K at my K1, and no other pieces. You have only K at K6 and R at R1. It is your move. What do you play?

A: (After a pause of 15 seconds) R-R8 mate.


Slika 1. Primjer razgovora u radu Alana Turinga

Izvor: <https://doi.org/10.1093/mind/lix.236.433>

2.3. ELIZA

ELIZA je prvi *chatbot* kojeg je 1966. godine razvio njemački MIT profesor Joseph Weizenbaum [5]. *Chatbot* ime ELIZA je dobio po fikcionalnom liku iz predstave *Pygmalion* - Eliza Doolittle [6]. ELIZA je mogla zavarati korisnike da pomisle da razgovaraju sa stvarnim čovjekom. Stvorena je kako bi pokazala površnost komunikacije između čovjeka i stroja. Njezina uloga je bila da oponaša psihoterapeuta pretvarajući izjave korisnika u pitanja, što bi stvorilo povjerenje korisnika. ELIZA je simulirala razgovor koristeći uspoređivanje uzoraka i metodu zamjene, ali nije mogla razumjeti kontekst rečenice. Komunicirala je prateći pravila i smjernice skripta, napisanih u MAD-Slipu, . Pomoću njih ELIZA je obrađivala ulazne korisničke podatke te se uključivala u razgovor. Negativna strana ELIZE je da nije mogla istinski razumjeti značenje razgovora

te je mogla raspravljati samo o određenim temama koje su bile napisane u skriptama. Kreator ELIZE bio je iznenađen velikim brojem ljudi koji su ELIZI pripisivali ljudske osobine. Mnogi su smatrali da bi ELIZA mogla imati pozitivan utjecaj na osobe koje se suočavaju s psihičkim problemima te kako bi mogla pomoći liječnicima u tretiranju takvih pacijenata [5].



Slika 2. Eliza primjer razgovora

Izvor: <https://doi.org/10.1631/fitee.1700826>

2.4. Parry

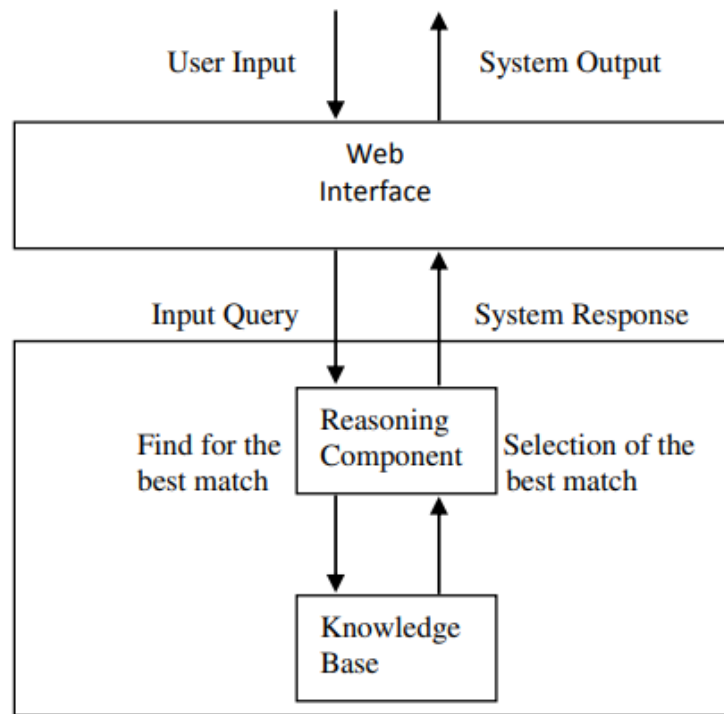
Kenneth Colby dizajnirao je 1975.godine Parry koji oponaša paranoičnu osobu. Parry, kao i ELIZA, je i dalje operira kao *chatbot* zasnovan na pravilima. Unatoč strukturnim sličnostima s ELIZOM, Parry se ističe po naprednijoj kontrolnoj strukturi i sposobnosti razumijevanja jezika, posebno po svom mentalnom modelu koji omogućuje *chatbotu* simulaciju emocija i osjećaja [7].

2.5. Jabberwacky

Jabberwacky je nastao 1988.godine kada je po prvi puta uvedena umjetna inteligencija u *chatbotove*. Razvijen je koristeći *Cleverscript* koji se temelji na proračunskim listovima te se oslanja na kontekstualno usklađivanje uzoraka kako bi mogao odgovoriti na temelju prethodnih razgovora. On je prvi *chatbot* koji je mogao učiti iz razgovora s ljudima. Jabberwacky nije bio sposoban za brze odgovore i nije prilagođen za rad s velikim brojem korisnika [8].

2.6. Alice

Alice (eng. *Artificial Linguistic Internet Computer Entity*) je nagrađivani *chatbot* otvorenog koda (*open source*) koji koristi AIML (eng. *Artificial Intelligence Mark-Up Language*) za generiranje odgovora na postavljene upite. Richard. S. Wallace ju je razvio 1995.godine inspiriran ELIZOM. Alice funkcionira na temelju prirodnog jezičnog razumijevanja i usklađivanju uzoraka pomoću kojih odgovara na upite korisnika. Unatoč tome, nije u mogućnosti proći Turingov test jer čak i obični korisnici mogu primijetiti nedostatke u njezinim odgovorima tijekom kraćih razgovora. Struktura Alice sastoji se od dva dijela: motora *chatbota* i jezičnog modela. Jezični model je pohranjen u AIML-u koji se smatra jednim od najjednostavnijih jezika *chatbotova* jer ima minimalistički dizajn. Osnovna jedinica u AIML-u je kategorija koja se sastoji od ulazne (pitanje) i izlazne (odgovor) informacije te konteksta koji je izboran. Pitanje predstavlja uzorak, odgovor predložak, a dva tipa izbornog konteksta se zovu *that* i *topic*. U AIML-u usklađivanje uzoraka je jako jednostavno jer se sastoji od riječi, razmaka i zamjenskih simbola `_` i `*`[5]. Alice-ina baza znanja sastojala se od 41 000 predložaka i uzoraka. No, Alice nije bila u mogućnosti kreirati odgovore slične ljudskima u izražavanju stavova ili emocija [8].



Slika 3. Struktura Alice

Izvor: <https://www.neliti.com/publications/263312/an-intelligent-behaviour-shown-by-chatbot-system>

2.7. Chatbotovi kao inteligentni osobni pomoćnici

Značajna revolucija u razvoju *chatbot* tehnologije dogodila se 2001.godine razvojem SmarterChild-a koji je bio integriran u *messengere* poput *AOL-a* i *MSN-a*. Predstavlja prekretnicu jer je to prvi puta da je *chatbot* mogao pomagati ljudima u svakodnevnim zadacima izvlačeći informacije iz različitih baza podataka o vremenu prikazivanja filmova, vijestima, itd. [8].

Korak dalje u razvoju bila je ugradnja osobnih pomoćnika u pametne telefone koji mogu razumjeti glasovne naredbe. Apple je razvio Siri 2010.godine. Ona omogućuje korisnicima postavljanje pitanja glasovnim naredbama putem *messengera*. Tijekom kontinuirane upotrebe Siri se prilagođava korisničkim jezičnom stilu, preferencijama te pretraživanju. Siri podržava više jezika iako ima problema u razumijevanju korisnika s jakim naglaskom ili u bučnim okruženjima [8].

IBM je razvio *Watsona* 2011.godine koji je razumio ljudski prirodni jezik toliko dobro da je pobijedio dva prvaka u kvizu *Jeopardy*. *Watsonov* nedostatak je što podupire samo engleski jezik [8].

Google Assistant evoluirao je iz *Google Now*-a 2016.godine. *Google Now* prvobitno je koristio za pružanje informacija korisniku uzimajući u obzir vrijeme dana, preferencije i lokacije korisnika, ali *Google Assistant* ide korak dalje predviđajući zahtjeve korisnika. Njegov nedostatak je taj da nema osobnost te budući da je povezan s *Google računom* korisnika postoji mogućnost da će doći do kršenja korisničke privatnosti [8].

2014.godine *Microsoft* razvija *Cortanu* osobnog pomoćnika koji može razumjeti glasovne zapovjedi, šalje *e-mailove*, upravlja popisima te traži informacije na zahtjev korisnika. Negativna strana *Cortane* je što može pokrenuti program za instaliranje *malware*-a [8].

Tijekom iste godine *Amazon* je predstavio *Alexu* koja je integrirana u kućne uređaje za automatizaciju i zabavu. Programeri mogu koristiti *Alexa Skills Kit* za stvaranje besplatnih ili plaćenih *Alexa vještina*. Međutim, identificirane su neke ranjivosti u sigurnosnoj zaštiti zbog slabe autentifikacije s jednim faktorom koja se lako može prekršiti s obzirom da se bazira na glasovnim naredbama bez pristupa koji ovisi o fizičkoj prisutnosti korisnika [8].

Također, iste godine *Microsoft* predstavlja *Xiaolice* društveni *chatbot* koji može razumjeti emocije. *Xiaolice* oponaša žensku osobu od 19 godina čija je primarna uloga uspostaviti emocionalnu vezu s korisnikom ponašajući se kao prijatelj koji bodri, razveseljava i ohrabruje. Zanimljivost i doprinos *chatbotovima* je taj da *Xiaolice* ima jednak omjer inteligencije (*IQ*) i emocionalne inteligencije (*EQ*) [7].

3. KONFIGURACIJA CHATGPT-A

Chatbotovi mogu pripadati više kategorija odjednom. Kategorije na koje se dijele su prema domeni znanja, usluzi koju pružaju, ciljevima, prema metodi odgovaranja na odgovore, ljudskom posredovanju, dozvolama te prema komunikacijskim kanalima. *Chatbotovi* na upite mogu odgovarati metodom usklađivanja uzoraka ili pomoću strojnog učenja.

3.1. Kategorije chatbotova

Chatbot Categories	Knowledge domain	Generic
		Open Domain
		Closed Domain
Service provided		Interpersonal
		Intrapersonal
		Inter-agent
Goals		Informative
		Chat based/Conversational
		Task based
Response Generation Method		Rule based
		Retrieval based
		Generative
Human-aid		Human-mediated
		Autonomous
Permissions		Open-source
		Commercial
Communication channel		Text
		Voice
		Image

Slika 4. Kategorije chatbotova

Izvor: <https://doi.org/10.1016/j.mlwa.2020.100006>

Domena znanja određena je rasponom znanja kojem *chatbot* može pristupiti. Ona se dijeli na tri glavne kategorije: generičke *chatbotove*, *chatbotove* s otvorenom i *chatbotove* sa zatvorenom domenom. Generički *chatbotovi* su sposobni odgovoriti na korisničko pitanje iz bilo koje domene (npr. Chorus). *Chatbotovi* s otvorenom domenom sudjeluju u više domena znanja (npr. Guardian, CRQA, AskWiz). Nasuprot njima, *chatbotovi* sa

zatvorenom domenom ograničeni su na specifičnu domenu znanja te mogu odgovarati na pitanja samo iz određene domene [8].

Chatbotovi koji pružaju uslugu kao što je na primjer rezervacija sjedala u avionu su interpersonalni *chatbotovi*. Oni se ne ponašaju kao prijatelji, nego samo izvršavaju određenu funkciju, Intrapersonalni *chatbotovi* se ponašaju kao bliski korisnikovi suradnici koji razumiju njega i njegove potrebe te žive u njegovoj domeni. Povezani su kroz aplikacije za slanje poruka kao što su WhatsApp ili Slack. Inter-agent *chatbotovi* služe za komunikaciju između *chatbotova* (npr. Cortana i Alexa) [8].

Chatbotovi se ovisno o cilju kojeg pokušavaju postići mogu podijeliti na informativne, razgovorne te temeljene na zadatku. Informativni *chatbotovi* se koriste kada je cilj brzo doći do informacije koja je pohranjena u fiksnom izvoru (npr. Facebook M, Guardian). Cilj razgovornih *chatbotova* je razgovor s korisnikom koji je prirodan i korisnik se osjeća kao da priča sa stvarnom osobom. Cilj razgovornih *chatbotova* je obavljanje nekog specifičnog zadatka kao npr. rezerviranje soba u hotelu. Oni su također jako dobri u zahtijevanju informacija od korisnika te prikladnom odgovaranju korisniku [8].

Metoda generiranja odgovora dijeli *chatbotove* na one bazirane na pravilima, dohvaćanju te generiranju. *Chatbotovi* bazirani na pravilima generiraju odgovore prateći set unaprijed definiranih pravila. *Chatbotovi* bazirani na dohvaćanju odabiru nekoliko odgovora prije nego što primjene usklađivanje uzoraka kako bi odabrali najbolji mogući odgovor. Generativni *chatbotovi* koriste algoritme strojnog učenja i tehnike dubokog učenja kako bi generirali odgovor koji se temelji na prethodnim porukama s korisnikom [9].

Ljudsko posredovanje se koristi za ispravljanje nedostataka potpuno autonomnih *chatbotova*. Ti nedostaci se mogu riješiti radom na integraciji inteligencije i znanja radnika u *chatbota*. Ljudsko posredovanje se koristi tamo gdje je potrebno više fleksibilnosti [8].

Ovisno o dozvolama koje pruži razvojna platforma, *chatbotovi* mogu biti otvorenog ili komercijalni. Razlikuju se po tome što komercijalne platforme ne daju punu kontrolu nad kodom programerima, dok platforme otvorenog koda distribuiraju svoj kod svima te programeri mogu modificirati taj kod [8].

Na posljetku, s obzirom na komunikacijski kanal *chatbotovi* se mogu podijeliti u one koji koriste tekstualni, slikovni ili glasovni unos. Također je moguće da jedan *chatbot* posjeduje sva tri unosa [8].

3.2. Usklađivanje uzoraka

Chatbotovi zasnovani na pravilima usklađuju unos korisnika s uzorkom pravila i odabiru unaprijed definirani odgovor iz skupa odgovora pomoću algoritma usklađivanja uzoraka [8]. Oni posjeduju bazu znanja koja sadrži dokumente s <uzorak> i <predložak>. Kada *bot* primi ulaz koji odgovara <uzorak>, šalje poruku koja je pohranjena u <predložak> kao odgovor [3]. *Chatbotovi* zasnovani na pravilima ne generiraju nove odgovore jer reproduciraju konverzacijske obrasce koje je unaprijed odredio programer. Što je veća njihova baza znanja, to će *chatbot* biti sposobniji odgovoriti na upite korisnika. Kako bi pravilno funkcionirali, *chatbotovima* zasnovanim na pravilima, potrebne su tisuće pravila. To znači da se teže mogu nositi s korisničkim gramatičkim pogreškama. Nedostatak usklađivanja uzoraka je da odgovori mogu postati repetitivni te nisu dovoljno spontani ili originalni u usporedbi s ljudskim odgovorima. Prednost ove vrste *chatbotova* je brzina odgovora zbog ne provođenja dublje semantičke i sintaktičke analize odgovora. Tri najčešća jezika koja se koriste za usklađivanje uzoraka su AIML, RiveScript i ChatScript [8].

3.2.1. AIML

AIML(eng. *Artificial Intelligence Markup Language*) jezik je otvorenog koda baziran na XML-u. Alice je bila prvi *chatbot* koji je imao bazu znanja implementiranu na AIML jeziku. AIML je popularan jezik među *chatbot* developerima zbog svoje jednostavnosti, lakoći učenja i primjene, upotrebljivosti i dostupnosti prethodno napisanih AIML zbirki. Međutim, nedostatak AIML-a je da se baza znanja kreirana na temelju podataka s interneta neće automatski ažurirati informacije, nego će zahtijevati periodičko ručno ažuriranje. AIML također ima slabe uzorke usklađivanja . Glavni izazov je potreba za ručnim unosom velike količine podataka kako bi se stvorio funkcionalni *chatbot* [10]. AIML objekti podataka organiziraju se u teme koje sadrže kategorije koje su relevantne za te teme. Kategorija predstavlja pravilo *chatbota* te se sastoji od uzorka koji predstavlja korisnički unos i predložka koji opisuje *chatbotov* odgovor. Uzorci mogu uključivati

riječi, simbole i prazna mjesta. Sve kategorije pohranjuju se u objekt *Graphmaster*. Kako bi se pronašao najbolji uzorak AIML koristi tehniku usklađivanja uzoraka koja započinje dubinskom pretragom u Graphmasteru [8].

User: Hello
Chatbot: Hi! What's your name?
User: My name is Eleni
Chatbot: Nice to meet you Eleni
User: Goodnight
Chatbot: Goodnight Eleni

Slika 5. Primjer razgovora

Izvor: <https://doi.org/10.1016/j.mlwa.2020.100006>

```
<category>
  <pattern> HELLO </pattern>
  <template>
    <random>
      <li> Hi! What's your name? </li>
      <li> Hello, How are you? </li>
      <li> Hello! </li>
    </random>
  </template>
</category>

<category>
  <pattern> MYNAME IS * </pattern>
  <template> Nice to meet you <set name="nameUser"> <star/> </set></template>
</category>

<category>
  <pattern> NIGHT </pattern>
  <template> Good night <get name="nameUser"/> </template>
</category>

<category>
  <pattern> _ NIGHT </pattern>
  <template> <srai> NIGHT </srai> </template>
</category>

<category>
  <pattern> NIGHT * </pattern>
  <template> <srai> NIGHT </srai> </template>
</category>

<category>
  <pattern> _ NIGHT * </pattern>
  <template> <srai> NIGHT </srai> </template>
</category>
```

Slika 6. Primjer AIML koda

Izvor: <https://doi.org/10.1016/j.mlwa.2020.100006>

3.2.2. RiveScript

RiveScript je linijski programski jezik koji implementira bazu znanja u *chatbotove* zasnovane na pravilima [11]. RiveScript je jednostavan jezik otvorenog koda koji se može koristiti u popularnim programskim jezicima poput Java, Pythona, C#. U RiveScript rečenici simbol + označava unos korisnika, a – odgovor *chatbota* [12].

```
+ Hello
- Hello. I am a chatterbot. How can I help you?
```

Slika 7. Primjer RiveScript koda

Izvor:

<https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=fbdb2ec93ee6cc62855cc75d595921573491b27a>

Tumač RiveScripta spaja korisnički unos s unaprijed definiranim okidačima i odabire najodgovarajući odgovor za taj unos. RiveScript također omogućuje upotrebu zamjenskih znakova, razgovornih preusmjerenja te je svjestan konteksta jer varijable korisnika i *chatbota*. Varijable *chatbota* mogu biti unaprijed definirane i programirane, dok se korisničke varijable mogu postaviti korištenjem dijelova korisničkog unosa [12].

3.2.3. Chatscript


Chatscript je napredan sustav za izradu *chatbotova* temeljenih na pravilima. Koristi programski jezik otvorenog koda koji je vrlo kompaktan. On usklađuje korisničke unose *chatbotovim* izlazima pomoću usklađivanja uzoraka. Chatscript prati skripte koje su kolekcije pravila. Pravila se sastoje od četiri dijela: tipa, etikete, uzorka u zagradama i izlaza. Jednostavno pravilo izgleda ovako: `?: MEAT (do you like meat) I love meat.[P][SEP]` [13]. Chatscript primjenjuje koncepte koji grupiraju slične riječi po njihovom značenju i drugim gramatičkim karakteristikama. Razvoji programeri mogu iskoristiti postojeće baze podataka, što pojednostavljuje izradu *chatbota*. Može detektirati emocije korisnika kada se koriste velika tiskana ili mala slova [8]

3.3. Strojno učenje

Chatbotovi koji primjenjuju tehniku strojno učenja analiziraju sadržaj korisničkog unosa putem obrade prirodnog jezika (*NLP*) [8]. Uzimaju kontekst razgovora u obzir te mogu učiti iz razgovora što znači da programeri ne moraju imati spreman odgovor za svaki korisnički unos. Međutim, ova tehnologija zahtjeva veliki set za treniranje *chatbota* kako bi naučio odgovore koji su prikladni. Problem se može pojaviti u odabiru podataka iz kojih će *chatbot* učiti. Neki podatci kao npr. filmske skripte bi mogli biti preširoki, dok razgovor između korisničke podrške i korisnika je previše specifičan. Također, problem kod korištenja podataka iz razgovora između ljudi je što što bi *chatbot* mogao naučiti neprikladne komentare [14].

3.3.1 Obrada prirodnog jezika (eng. *Natural Language Processing*)

NLP je područje umjetne inteligencije i lingvistike koje je usmjereno na razumijevane napisanih izjava ili riječi na ljudskom jeziku. NLP je nastao kako bi udovoljio potrebi ljudi za komunikacijom s računalima te kako bi se olakšao rad korisnika. NLP se može podijeliti na dva dijela: *NLU* (eng. *Natural Language Understanding*) i *NLG* (eng. *Natural Language Generation*) [15].



Slika 8. Podjela NLP-a

Izvor: <https://doi.org/10.1007/s11042-022-13428-4>

Razine NLP područja koje se međusobno isprepliću su:

- Morfološka razina – prvi korak analize je morfološka analiza. Morfem se definira kao najmanja jedinica riječi koja nosi neko značenje. Stem označava osnovni dio riječi koji nosi inherentno značenje. Afiks, s druge strane, je dodatak riječi koji joj pridodaje dodatno značenje. Najčešći tipovi afiksa su sufiksi i prefiksi [16].

- Leksička razina – analizira se svaka riječ kako bi se odredila njezina leksička kategorija (npr. imenica, pridjev, glagol, itd.) te se utvrđuju karakteristike kao što su broj (jednina, množina) [16].
- Sintaktička razina - sintaktična analiza razdvaja rečenice na njihove komponentne dijelove. Glavni fokus sintakse leži u pravilima i uvjetima koji su određeni gramatikom [16].
- Semantička razina – povezana je s otkrivanjem značenja u rečenicama, za razliku od sintaktičke analize koja se bavi strukturom rečenica. Većina riječi ima višestruka značenja, a određivanje preciznog značenja ovisi o kontekstu, odnosno položaju riječi u rečenici. Semantičkom analizom rečenice se pretaču u oblik koji omogućuje izvođenje zaključaka [16].
- Govorna razina – govorna razina se primjenjuje u okviru NLP-a kako bi se utvrdilo značenje rečenica, temeljem interakcije s drugim rečenicama unutar istog teksta ili segmenta nekog dokumenta [16].
- Pragmatična razina - istražuje analizu rečenica i njihove potencijale za različite primjene u različitim situacijama. Ona precizno definira kontekst rečenice, uključujući odnos između vremena kada je rečenica izgovorena i vremena na koje se odnosi [16].



Slika 9. Razine NLP-a

Izvor: : <https://doi.org/10.31784/zvr.9.1.23>


3.3.2. NLU

NLU je baza svakog NLP zadatka. Osnovni cilj NLU-a je izvući kontekst i značenje iz korisničkih unosa prirodnog jezika [9]. NLU omogućuje strojevima da razumiju prirodan jezik kojeg analiziraju kako bi izvukli različite elemente kao što su koncepti, subjekti, emocije, ključne riječi itd. Ova tehnologija se koristi u aplikacijama za korisničku podršku kako bi se bolje razumio problem kojeg su prijavili korisnici [15]. NLU

dekomponira jezik na manje jedinice *part of speech* ili čak manje morfeme s ciljem da razumije pravo značenje teksta ili govora. Ovo postiže analizom sintakse i semantike kroz uporabu gramatike, leksikona te različitih algoritama i mehanizama ove analize. NLU transformira nestrukturirane podatke poput teksta ili govora u strukturirane informacije te traži semantičko značenje u danom tekstu [16].

3.3.3. NLG

NLG je proces stvaranja izraza, rečenica i odlomaka s jasnim značenjem iz unutarnje reprezentacije. Sastoji se od četiri koraka: prepoznavanje ciljeva, planiranje kako postići te ciljeve procjenom situacije i raspoloživih komunikacijskih resursa te konačno izvođenje tih planova kroz generiranje teksta [8]. NLG proces se bavi stvaranjem smislenih fraza i rečenica na prirodnom jeziku, nastoji stvoriti govor ili tekst koji odgovara ulazu ili ga reproducira na način razumljiv ljudima. Koristi strukturirane informacije kako bi generirao tekst ili govor [16]



Slika 10. Ciklus razumijevanja i generiranja prirodnog jezika

Izvor: : <https://doi.org/10.31784/zvr.9.1.23>

4. CHATGPT

ChatGPT (eng. *Generative Pre-Trained Transformer*) je napredna inačica *GPT-3* posebno stvorena za konverzacijsku umjetnu inteligenciju. Sposoban je stvarati dijaloge koristeći prirodni jezik te pružiti poboljšane odgovore na različita pitanja davanjem više konteksta oko riječi kako bi *AI* razumio bolje što se od njega traži [17].

GPT modeli su stvoreni s namjerom da generiraju tekst prirodnog jezika, uključujući rečenice, odlomke te cijele dokumente s koherentnošću i dosljednošću karakterističnom za ljudski jezik. Ključna karakteristika GPT modela leži u njihovoj sposobnosti prethodne obuke na velikim skupovima tekstualnih podataka te naknadnom prilagodbom za specifične zadatke kao što su tekstualna klasifikacija ili odgovaranje na pitanja. U tijeku prethodne obuke, GPT model se uči predviđati sljedeću riječ u tekstu, uzimajući u obzir prethodne riječi u nizu. Ovaj zadatak, poznat kao modeliranje jezika, predstavlja ključni element mnogih zadataka obrade prirodnog jezika. Obučavanjem na velikom korpusu tekstualnih podataka, model stječe sposobnost prepoznavanja i generaliziranja jezičnih obrazaca poput sintakse, gramatike i semantike [18]. Nakon faze prethodne obuke, GPT model se može prilagoditi određenom zadatku koristeći manji skup označenih podataka. Ovi podaci ažuriraju težine i pristranosti modela kako bi bolje odgovarali specifičnom zadatku [19].

4.1. Povijest ChatGPT-a

U narednim potpoglavljima biti će sistematizirano prikazan povijesni razvoj ChatGPT-a od strane OpenAI organizacije 2015. godine.

4.1.1. OpenAI

OpenAI je organizacija posvećena razvoju umjetne inteligencije za dobrobit čovječanstva. Osnovana je 2015.godine od strane utemeljitelja kao što su Elon Musk, Sam Altman i drugi. OpenAI je pionir u području istraživanja umjetne inteligencije, uspješno je stvorio nekoliko revolucionarnih modela kao što su GPT-2, GPT-3 i ChatGPT. ChatGPT je dizajniran za učinkovito obavljanje razgovornih zadataka te donosi značajna poboljšanja u razumijevanju konteksta, generiranju odgovora i ukupnoj koherentnosti u usporedbi s GPT-3 [20].

4.1.2. GPT-1

Prvi put je predstavljen 2018.godine. Temelji se na transformer arhitekturi, neuronskoj mreži koja je konstruirana za zadatke obrade prirodnog jezika poput modeliranja i strojnog prevođenja. Ovaj model je naučio predviđati sljedeću riječ u rečenici, uzimajući u obzir prethodne riječi. Kroz ovaj proces predobuke, GPT-1 stekao je sposobnost prepoznavanja obrazaca i veza između riječi unutar velikog korpusa tekstualnih podataka. Može se prilagoditi različitim zadacima kao što su prevođenje jezika, analiza sentimenta ili klasifikacija teksta. Posjedovao je 117 milijuna parametara što ga čini manjim u usporedbi s kasnijim verzijama GPT-a [20].

4.1.3. GPT-2

Posjeduje 1.5 milijardi parametara što ga čini jedim od najvećih jezičnih modela u vrijeme njegova nastanka. Treniran je na obimnom korpusu tekstualnih podataka kao što su web stranice i knjige korištenjem jezičnog modeliranja. Imao je sposobnost generacije dužih i koherentnijih tekstova te je pokazivao bolju sposobnost prilagodbe na nove zadatke i domene [20].

4.1.4. GPT-3

Ovaj model predstavlja jedan od najvećih i najmoćnijih jezičnih modela koji su ikada stvoreni. Posjeduje čak 175 milijardi parametara što je nekoliko puta veće od GPT-2. Posjeduje sposobnost generiranja visokokvalitetnog teksta na prirodnom jeziku s izraženom koherentnošću i realističnošću. Zbog mogućnosti da nauči širok spektar jezičnih karakteristika i uzoraka tijekom predobuke ima izuzetnu sposobnost za obavljanje raznolikih prirodnih jezičnih zadataka kao što su klasifikacija teksta, analiza sentimenta te pitanja i odgovori, bez potrebe za specifičnim skupom podataka za svaku pojedinu zadaću. GPT-3 posjeduje inovativne značajke kao što je višezadačno učenje što omogućava modelu da istovremeno obavlja više zadataka te da uči iz malog broja primjera [20].

4.1.5. InstructGPT

Koristi tehnike učenja s pojačanjem (eng. *reinforcement learning*) uz ljudske povratne informacije (*RLHF*) kako bi poboljšao svoju pouzdanost. Ljudi stvaraju i uspoređuju željene izlaze s onima koje generira GPT na manjem skupu podataka. Oni označavaju izlaz koji generira GPT prema ljudskim povratnim informacijama te taj izlaz prikazuju modelu GPT kako bi ga bolje usmjerili prema željenim rezultatima u specifičnim zadacima i pitanjima. Ovaj pristup postao je standardna praksa unutar OpenAI tehnologije [20].

4.1.6. ChatGPT

Obučen je na velikom korpusu tekstualnih podataka koji uključuju knjige, web stranice i članke koristeći zadatak jezičnog modeliranja. ChatGPT uči obrasce i odnose između riječi i fraza u prirodnom jeziku pomoću predobuke. To ga čini učinkovitim u stvaranju realističnih i koherentnih odgovora u razgovoru [20].

4.1.7. GPT-4

Ovaj model je veliki multimodalni jezični model koji može prihvatiti slikovne i tekstualne ulaze i generirati tekstualne izlaze. Pokazao izvedbu sličnu ljudskoj na različitim profesionalnim i akademskim kriterijima, Postigao je rezultat od oko 10% najboljih ispitanika na simuliranom pravosudnom ispitu, što je bolje od GPT-3.5 čiji rezultat iznosi od oko 10% najnižih [20].

4.2. Tehnologija iza ChatGPT-a

Iako tehnički detalji poput arhitekture, hardvera, strukture skupa podataka i metoda obuke nisu dostupni, osnovne tehnike GPT-4 ostaju slične onima GPT-3 ili GPT-3.5 [21].

4.2.1. Prethodno obučeni jezični model

Jezični modeli su statistički modeli koji opisuju distribuciju vjerojatnosti prirodnog jezika. Prethodno obučeni jezični model je model koji se koristi za procjenu vjerojatnosti različitih aspekata prirodnog jezika što je temeljni zadatak obrade prirodnog jezika i može se koristiti na gotovo svim NLP zadacima. Za modeliranje statističkih jezičnih modela

koriste se različite metode i pristupi. U ranoj verziji n-gram jezičnog modela (eng. *N-gram Language Model*) uvjetna vjerojatnost se procjenjuje na temelju statistike učestalosti n grama. Ovaj model uzima u obzir samo fiksnu duljinu niza riječi, što se temelji na Markovljevoj pretpostavci. N-gram jezični model igrao je ključnu ulogu u razvoju tehnologije pretrage temeljene na ključnim riječima i određivanju relevantnosti dokumenta. Lansiranje modela neuronskog jezika (eng. *Neural Language Model - NLM*) [39], 2010. godine potaknulo je istraživače na dublje modeliranje složenih aspekata prirodnog jezika i izvođenje različitih zadataka putem raznovrsnih dubokih neuronskih mreža, uključujući višeslojni perceptron (eng. *Multilayer Perceptron - MLP*), konvolucijske neuronske mreže (eng. *Convolutional Neural Network - CNN*) i rekurentne neuronske mreže (eng. *Recurrent Neural Network - RNN*). Također su razvijeni reprezentativni statični jezični modeli kao što su *word2vec* i *RNNLM* (eng. *Recurrent Neural Network Language Model*). NLM koristi nisko-dimenzionalna ugrađivanja za reprezentaciju riječi i njihovih sastavnih dijelova, te postiže predviđanje uvjetnih vjerojatnosti putem obrade neuronske mreže. Od 2018.godine prethodno obučeni jezični modeli (eng. *Pre-trained Language Model - PLM*) koji se temelje na samonadziranom učenju iz obimnih tekstova postaju sve važniji. Ova promjena potiče razvoj dvostupanjske paradigme učenja koja uključuje fazu predobuke i fino podešavanje modela. PLM-ovi se obučavaju na općenitim jezičnim modelima koristeći velike tekstualne korpuse i kroz samoučenje rješavaju zadatke kao što su predviđanje maskiranih riječi, prepoznavanje uzoraka rečenica, popunjavanje praznina u tekstu i generiranje teksta. PLM-ovi pružaju sveobuhvatni okvir za modeliranje različitih zadataka obrade prirodnog jezika. Trenutno postoje tri osnovna tipa PLM-a: autoregresivni jezični model, autokodirajući jezični model i hibridni jezični model. OpenAI slijedi autoregresivni pristup [21].

4.2.2. ICL

ICL (eng. *In-Context Learning*) omogućuje modeliranje dubljeg konteksta za rješavanje specifičnih zadataka. Ono pomaže u boljem rješavanju situacija gdje ima malo ili nimalo dostupnih podataka za učenje. Zahvaljujući ICL-u modeli u seriji GPT 3.5 mogu postizati značajne rezultate bez specifičnog treninga ili finog podešavanja za različite zadatke obrade prirodnog jezika [21].

ICL (eng. *In-Context Learning*) omogućuje modelu da uči i izvršava zadatke kroz imitaciju zbog dodavanja nekoliko primjera u kontekst. Osnovna ideja ICL-a fokusira se na učenje putem analogija za izvršavanje zadataka. ICL ne zahtjeva ažuriranje parametara, nego on direktno provodi analogno učenje i i predviđanje zadataka na temelju već prethodno naučenih jezičnih modela. Oslanja se na sposobnost modela da otkrije skrivene obrasce u demonstracijama kako bi postigao precizna predviđanja. Prilagodбом ICL-a moguće je ostvariti učenje s malo napora ili vrlo malim brojem pokušaja koristeći jasne opise zadataka ili dodavanjem nekoliko primjera kao smjernica [21].

Lanac misli (eng. *Chain of Thought – CoT*) se usredotočuje na izradu niza koraka koji oponašaju razmišljanje ljudi tijekom izvođenja kompleksnih zadataka. Upotrebom CoT-a jezični modeli poput GPT-3 mogu istovremeno generirati korake obrazloženja i odgovore [21].

Fino podešavanje uputa (eng. *Instruction Fine Tuning*) služi kako bi se poboljšala sposobnost generalizacije velikih jezičnih modela, istraživači su počeli istraživati koncept finog podešavanja uputa. Ovaj pristup uključuje opisivanje svih zadataka obrade prirodnog jezika putem uputa napisanih prirodnim jezikom, a zatim fino podešavanje velikih jezičnih modela kako bi se postigla opća sposobnost razumijevanja i izvršavanja tih uputa [21].

4.2.3. Podržano učenje

Podržano učenje (eng. *Reinforcement Learning From Human Feedback*) uglavnom se fokusira na postizanje optimalne politike za maksimiziranje željene nagrade ili ostvarivanje specifičnih ciljeva putem interakcije između agenta i okoline. Jedan od glavnih čimbenika za treniranje uspješnog agenta za podržano učenje je dobro specificirana funkcija nagrađivanja. Međutim, za zadatke koji su loše definirani teško je konstruirati preciznu funkciju nagrađivanja za procjenu jeli zadatak dobro odrađen s ograničenim informacijama senzora. Kako bi se izbjegla neskladnost između ljudskih preferencija i ciljeva agenata za pojačano učenje, često se koristi ljudska intuicija i stručnost za prijenos znanja. Direktno korištenje ljudskih povratnih informacija tijekom treniranja agenta može biti skupo zbog velike količine iskustva kojeg je potrebno ručno evaluirati. Proces treniranja modela za nagrađivanje može se podijeliti u tri koraka:

- 1) agent stupa u interakciju s okolinom prema trenutnoj politici π kako bi prikupio niz putanja stanja, radnji i nagrada,
- 2) Iz tih se sekvenci izabiru segmenti, koji se zatim šalju ljudima na usporedbu i procjenu,
- 3) Parametri modela nagrađivanja ažuriraju se kroz nadzirano učenje kako bi se uskladili s ljudskim preferencijama [21].

4.3. Primjena ChatGPT-a

Napretkom i razvojem ChatGPT-a proširila se i upotreba ove vrste tehnologije kako bi se unaprijedio i olakšao posao unutar različitih grana industrije. Danas se njegova primjena seže od medicine i zdravstva do prodaje i marketinga.

Medicina i zdravstvo:

- Trijaža pacijenata putem *chatbota*: ChatGPT može poslužiti za stvaranje *chatbota* koji pomaže u procjeni hitnosti pacijentovog stanja, podržavajući zdravstvene stručnjake u određivanju potrebnih postupaka.
- Medicinska dijagnoza i liječničke preporuke: ChatGPT se može iskoristiti za razvoj sustava koji podržava medicinsku dijagnozu i nudi preporuke za terapiju. Analizom simptoma i podataka o pacijentu, ChatGPT pruža zdravstvenim stručnjacima smjernice za dijagnozu i liječenje.
- Edukacija iz područja medicine: ChatGPT može biti osnova za sustave koji podržavaju medicinsku edukaciju. Pružanjem informacija o medicinskim uvjetima i tretmanima, ChatGPT pridonosi obrazovanju zdravstvenih djelatnika i pacijenata.
- Savjetovanje o mentalnom zdravlju: ChatGPT se može koristiti za razvoj *chatbota* koji pacijentima pruža podršku u vezi mentalnog zdravlja. Analizom pacijentovih podataka i davanjem prilagođenih smjernica, ChatGPT doprinosi upravljanju mentalnim zdravstvenim stanjima.
- Povećanje uključenosti pacijenata i pridržavanje terapije: ChatGPT se može primijeniti za razvoj sustava koji potiče angažman pacijenata i potporu

pridržavanju terapije. Davanjem individualnih preporuka i podsjetnika, ChatGPT pomaže pacijentima da slijede plan liječenja.

- Klinička istraživanja i razvoj novih pristupa: ChatGPT se može iskoristiti za analizu velike količine kliničkih podataka, otkrivanje uzoraka i trendova koji mogu informirati razvoj novih tretmana i intervencija [20]

Pravo i pravne usluge:

- Sažimanje pravnih dokumenata
- Pružanje pomoći prilikom izrade pravnih dokumenata
- Pružanje brzih i preciznih odgovora na pravna pitanja analizom relevantnih zakona i presedana [20]

Obrazovanje:

- Izrada personaliziranih obrazovnih materijala i planova lekcija
- Pružanje povratnih informacija i smjernica učenicima tijekom učenja
- Pomoć pri ocjenjivanju zadataka
- Pružanje povratnih informacija o učenicima [20]

Programiranje:

- Generiranje koda – ChatGPT može pružiti korisnicima isječke koda analizom podataka o programskom jeziku, funkciji i zahtjevima
- Optimizacija koda – analizom podataka o programskom jeziku, algoritmima i strukturama podataka ChatGPT može pomoći programerima da poboljšaju performans i učinkovitost svog koda
- Pomoć pri otklanjanju pogrešaka - ChatGPT daje preporuke za strategije i tehnike otklanjanja pogrešaka analizom podataka o programskom jeziku, strukturi koda i porukama o pogreškama
- Dokumentacija koda – ChatGPT pruža preporuke za najbolji način i standarde dokumentacije koda, pomaže programerima u stvaranju jasne i koncizne dokumentacije [21]

Bankarstvo:

- Chatbotovi korisničke podrške - ChatGPT nudi prilagođene preporuke koje dodatno unaprjeđuju korisničko iskustvo
- Detekcija financijskih prijevara – ChatGPT analizira informacije o transakcijama te prepoznaje trendove koji ukazuju na nepošteno ponašanje
- Upravljanje investicijama – ChatGPT može pomoći financijskim institucijama u donošenju informiranih odluka o investicijama analizirajući financijske podatke
- Osobne financije - Kombinirajući podatke o ponašanju i preferencijama korisnika ChatGPT pruža personalizirane preporuke koje pomažu korisnicima unaprijediti svoje financijsko stanje
- Upravljanje bankarskim rizicima – ChatGPT se može koristiti za razvoj sustava koji pomaže prilikom upravljanja rizicima u bankarskom sektoru. On identifikacijom potencijalnih opasnosti pruža financijske informacije [20].

Prodaja i marketing:

- Generiranje potencijalnih klijenata – analizom podataka o ponašanju i preferencijama kupaca ChatGPT može pomoći u generiranju klijenata
- Chatbotovi za korisničku podršku - kroz analizu podataka o ponašanju klijenata i njihovim preferencijama ChatGPT može pružiti prilagođene preporuke koje poboljšavaju iskustvo korisnika
- Analiza tržišta i prognoza - ChatGPT može analizirati veliku količinu marketinških podataka, može identificirati obrasce i trendove koji mogu poslužiti za razvoj marketinških strategija i kampanja
- Stvaranje marketinškog sadržaja - ChatGPT može pomoći prilikom izrade marketinškog sadržaja. ChatGPT može generirati prirodne jezične odgovore koji su informativni i zanimljivi analizom ciljane publike
- Poboljšanje prodaje - Korištenjem podataka o ponašanju i preferencijama kupaca, ChatGPT pruža alate stručnjacima potrebne za postizanje uspješnijih rezultata [20]

Vlada i politika:

- Poboljšanje pristupa biračima
- Vođenje kampanje
- Poboljšanje analize politike
- Poboljšavanje analize govora
- Optimizacija raspodjele resursa [23]

Vijesti i mediji:

- Poboljšanje društvenog utjecaja analizom različitih korisnika
- Prepoznavanje pozitivnih i negativnih trendova u vijestima [17]

Umjetnost i književnost:

- ChatGPT pruža platformu za brzo generiranje sadržaja
- Pristup povratnim informacijama čitatelja realnom vremenu
- Pomaže u kreativnim procesima kao što su skiciranje, uređivanje i ispravljanje [24]

5. ZAKLJUČAK

ChatGPT predstavlja značajan korak prema napretku u polju obrade prirodnog jezika i interakciji između ljudi i računalnih sustava. Omogućio je stvaranje autentičnih i smislenih razgovora s računalom, što otvara mnoge mogućnosti u područjima poput korisničke podrške, obrazovanja, medicine, bankarstva itd. ChatGPT je oblik prirodne obrade jezika koja je omogućila neviđene razine automatizacije u komunikaciji. Temelj ChatGPT-a je njegova sposobnost da uči iz velikog korpusa podataka. On je prethodno obučeni jezični model koji uči u dvije faze. Prva faza je predobuka gdje se ChatGPT obučava na velikoj količini tekstualnih podataka što mu omogućuje razumijevanje jezika i jezičnih obrazaca, a druga faza finog podešavanja modela koja ga prilagođava specifičnim zadacima ili domenama. Pokazuje impresivnu jezičnu kompetenciju, što ga čini korisnim alatom za različite jezične zadatke. ChatGPT može razumjeti kontekst razgovora pomoću kontekstualnog razumijevanja jezika ICL-a i generirati relevantne odgovore zbog čega je učinkovit u oponašanju ljudskih interakcija. On proizvodi koherentan, gramatički i kontekstualno točan tekst. Također, može ga se dodatno podesiti za specifične zadatke ili domene, što povećava njegovu primjenjivost u različitim industrijama. Trenutno najrazvijenija verzija ChatGPT-a je GPT-4 koja može prihvatiti tekstovne i slikovne ulaze što dodatno proširuje primjenu ChatGPT-a. Ova verzija nije dostupna za besplatno korištenje. S obzirom na rapidan razvoj GPT modela i trenutnu upotrebu u raznim industrijama, u budućnosti bi ova tehnologija mogla još više proširiti područje primjene na veći broj industrija.

6. LITERATURA

- [1] IBM (2023). *What is a chatbot?*, dostupno na: <https://www.ibm.com/topics/chatbots>, datum pristupa: 2.9.2023.
- [2] Sansonnet J.P, Leray D., Martin J. (2006). *Architecture of a framework for generic assisting conversational agents*, dostupno na: https://doi.org/10.1007/11821830_12, datum pristupa 2.9.2023.
- [3] Cahn J. (2017). *CHATBOT: Architecture, Design, & Development*, diplomski rad, University of Pennsylvania
- [4] Turing A. (1950). *Computing Machinery and Intelligence*. *Mind*, Vol. LIX, No.236., Listopad 1950., 433–460
- [5] Sharma V., Goyal M., Malik D. (2017)., *An intelligent behaviour shown by Chatbot system*, *International Journal of New Technology and Research*, Vol. 3, No. 4, Travanj 2017., 52-54
- [6] Tutiš I. (2022). *Implementacija automatiziranog sustava za generalni tekstualni razgovor (eng. chatbot)*, Diplomski rad. Zagreb: Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet.
- [7] Shum H., He X., Li D. (2018). *From Eliza to XiaoIce: challenges and opportunities with social chatbots*, *Frontiers of Information Technology & Electronic Engineering*, 19(1), 10–26.
- [8] Adamopoulou E., & Moussiades, L. (2020). *Chatbots: History, technology, and applications*. *Machine Learning with Applications*, Vol. 2, No. 100006., dostupno na: <https://doi.org/10.1016/j.mlwa.2020.100006>, datum pristupa: 2.9.2023.
- [9] Adamopoulou, E., Moussiades, L. (2020). *An Overview of Chatbot Technology*. Maglogiannis, I., Iliadis, L., Pimenidis, E. (ur.) *Artificial Intelligence Applications and Innovations*. AIAI 2020. IFIP Advances in Information and Communication Technology, vol 584. Springer, Cham. https://doi.org/10.1007/978-3-030-49186-4_31
- [10] Arsovski, S., Muniru, I., & Cheok, A. (2017). *Analysis of the chatbot open source languages aiml and chatscript: A review*, dostupno na: https://www.researchgate.net/publication/323279398_ANALYSIS_OF_THE_CHATB

[OT OPEN SOURCE LANGUAGES AIML AND CHATSCRIPT A Review.](#)

datum pristupa 2.9.2023

[11] Petherbridge N. (2023). *Rivescript*, dostupno na:

<https://www.rivescript.com/about> , datum pristupa 2.9.2023

[12] Gupta, S., Borkar, D., Mello, C. D., Patil, S. (2015). *An e-commerce website based chatbot*, International Journal of Computer Science and Information Technologies, Vol. 6, 2015., No. 2, 1483-1485.

[13] Wilcox B., Wilcox S. (2013). *Making it Real: Loebner-winning Chatbot Design*, Arbor, Vol. 189, No.764, dostupno na:

<https://arbor.revistas.csic.es/index.php/arbor/article/view/1888/2079> , datum pristupa: 3.9.2023

[14] Lin L., D'Haro L. F., Banchs R. E. (2016). *A Web-based Platform for Collection of Human-Chatbot Interactions*. ResearchGate, 363–366, dostupno na:

<https://doi.org/10.1145/2974804.2980500>, datum pristupa: 3.9.2023.

[15] Khurana, D., Koli, A., Khatter, K., Singh, S. (2022). *Natural language processing: state of the art, current trends and challenges*, Multimedia Tools and Applications, Vol. 82, No.3, 3713–3744.

[16] Šuman, S. (2021). PREGLED METODA OBRADE PRIRODNIH JEZIKA I STROJNOG PREVOĐENJA. *Zbornik Veleučilišta u Rijeci*, 9 (1), 371-384.

[17] M. Abdullah, A. Madain and Y. Jararweh, ChatGPT: Fundamentals, Applications and Social Impacts, 2022 Ninth International Conference on Social Networks Analysis, Management and Security (SNAMS), Milano, Italy, 2022., 1-8

[18] Kumar B. (2023). *GPT-1, GPT-2 and GPT-3 models explained*, dostupno na: <https://360digitmg.com/blog/types-of-gpt-in-artificial-intelligence> , datum pristupa: 3.9.2023.

[19] Shree P. (2020). *The Journey of Open AI GPT models*, dostupno na:

<https://medium.com/walmartglobaltech/the-journey-of-open-ai-gpt-models-32d95b7b7fb2> , datum pristupa: 3.9.2023.

- [20] Ray P.P. (2023). *ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope*, dostupno na: https://www.sciencedirect.com/science/article/pii/S266734522300024X?ref=pdf_download&fr=RR-2&rr=8011a89659a12482 , datum pristupa: 3.9.2023.
- [21] Stackoverflow. (2022). *Temporary policy: Chatgpt is banned*, dostupno na: <https://meta.stackoverflow.com/questions/421831/temporary-policychatgpt-is-banned>, datum pristupa: 3.9.2023.
- [22] Wu, T., He, S., Liu, J., Sun, S., Liu, K., Han, Q., & Tang, Y. (2023). *A brief overview of ChatGPT: the history, status quo and potential future development*, IEEE/CAA Journal of Automatica Sinica, Vol. 10, No. 5, Svibanj 2023.,1122-1136,
- [23] Bahrini, A., Khamoshifar, M., Abbasimehr, H., Riggs, R. J., Esmaeili, M., Majdabadkohne, R. M., & Pasehvar, M. (2023). *ChatGPT: Applications, Opportunities and Threats*, 2023 Systems and Information Engineering Design Symposium (SIEDS), Charlottesville, VA, USA, 2023, 274-279.
- [24] Zhang, B., Ding, D., & Jing, L. (2022). *How would Stance Detection Techniques Evolve after the Launch of ChatGPT?*, dostupno na: <https://doi.org/10.48550/arxiv.2212.14548>, datum pristupa: 7.9.2023

POPIS SLIKA

Slika 1. Primjer razgovora u radu Alana Turinga	3
Slika 2. Eliza primjer razgovora	4
Slika 3. Struktura Alice.....	6
Slika 4. Kategorije chatbotova.....	8
Slika 5. Primjer razgovora	11
Slika 6. Primjer AIML koda	11
Slika 7. Primjer RiveScript koda	12
Slika 8. Podjela NLP-a.....	13
Slika 9. Razine NLP-a	14
Slika 10. Ciklus razumijevanja i generiranja prirodnog jezika.....	15