

Utjecaj umjetne inteligencije i obrade prirodnog jezika na učinkovitost poslovnog procesa standardizacije nestrukturiranih tekstualnih podataka

Buzov, Antonija

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:124:916195>

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

Download date / Datum preuzimanja: **2024-09-28**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**UTJECAJ UMJETNE INTELIGENCIJE I
OBRADU PRIRODNOG JEZIKA
NA UČINKOVITOST POSLOVNOG PROCESA
STANDARDIZACIJE NESTRUKTURIRANIH
TEKSTUALNIH PODATAKA**

Mentor: Prof. dr. sc. Mario Jadrić

Student: Antonija Buzov

Split, kolovoz 2024.

Za moje ljubičice.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, Antoniija Jurov,
(ime i prezime)

izjavljujem i svojim potpisom potvrđujem da je navedeni rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja na objavljenu literaturu, što pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio navedenog rada nije napisan na nedozvoljeni način te da nijedan dio rada ne krši autorska prava. Izjavljujem, također, da nijedan dio rada nije korišten za bilo koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Split, 2024. godine

Vlastoručni potpis : 

SADRŽAJ:

1. UVOD	6
1.1. Problem istraživanja	6
1.2. Predmet istraživanja	11
1.3. Istraživačka pitanja	12
1.5. Metode istraživanja	15
1.6. Doprinost istraživanja	17
1.7. Struktura i sadržaj diplomskog rada	18
2. UMJETNA INTELIGENCIJA U OBRADI PRIRODNOG JEZIKA	20
2.1. Obrada prirodnog jezika	20
2.2. Strojno i duboko učenje	22
2.3. Kognitivna psihologija	26
2.4. Računalna lingvistika	27
3. UTJECAJ UMJETNE INTELIGENCIJE NA POSLOVANJE	29
3.1. Učinkovitost procesa	33
3.2. Generiranje uvida	34
3.3. Transformacija poslovnih procesa	35
3.4. Operativni učinak	35
3.5. Financijski učinak	36
3.6. Učinak temeljen na tržištu	37
3.7. Učinak na održivost	38
4. EKSPERIMENTALNI DIO ISTRAŽIVANJA	39
4.1. Programski jezik Python	39
4.2. Programski kod	42
4.3. Pomoćni alati	49
5. REZULTATI ISTRAŽIVANJA	54

6. RASPRAVA	63
7. ZAKLJUČAK	64
LITERATURA	65
SAŽETAK	74
SUMMARY	74

1. UVOD

1.1. Problem istraživanja

Pojam umjetne inteligencije prisutan je u društvu od 50-ih godina prošlog stoljeća kao futurističko i još nedostižno stanje, no proteklih godina ova tehnologija postaje sveprisutna i dostupna svima. Razni oblici umjetne inteligencije postali su svakodnevnica bez koje je nemoguće obavljati mnoge zadatke i rješavati probleme, kako u poslovnom, tako i u privatnom svijetu. Iako postoje različite definicije umjetne inteligencije, Rich (1985) daje konciznu definiciju koja na jednostavan način predstavlja svrhu umjetne inteligencije: „*Umjetna inteligencija je znanost o tome kako natjerati računala da rade stvari u kojima su ljudi trenutno bolji.*“

Cilj korištenja umjetne inteligencije je omogućiti računalima da na brži i točniji način riješe zadane probleme, prepoznaju obrasce ponašanja, donose odluke, stvaraju samoorganizirajuće sustave te obrađuju prirodne, odnosno ljudske jezike (Hunt, 2014). Upravo je obrada prirodnog jezika (*eng. Natural Language Processing – NLP*) jedan od glavnih fokusa današnjeg *Big Data* okruženja koje, uključujući tekstualne i zvukovne nestrukturirane podatke, otežava pohranjivanje, pripremu, prikazivanje i obradu podataka. Podatci koji svakim danom rastu u obujmu, vrsti i kompleksnosti, sve se više udaljavaju od klasičnih transakcijskih podataka na koje su softveri za analizu naviknuti. Današnje podatke čine fotografije, audio i video zapisi, elektronička pošta, objave na društvenim mrežama i sl., a što značajno otežava analizu podataka i dolazak do potrebnih informacija. Obrada prirodnog jezika omogućuje automatsku manipulaciju prirodnih jezika koje je računalima dosad bilo teško razumjeti pošto koriste umjetno stvorene računalne jezike. Goldberg (2017) u svojoj knjizi *Metode neuronskih mreža za obradu prirodnog jezika* NLP definira kao područje dizajniranja metoda i algoritama koji uzimaju prirodni jezik kao ulaz (*input*) ili ga proizvode kao izlaz (*output*). Drugim riječima, NLP modeli mogu koristiti prirodne jezike kako bi iz njih kreirali strukturirane podatke (*eng. Natural Language Understanding*) ili iz strukturiranih podataka kreirali prirodni jezik (*eng. Natural Language Generation*) kao rezultat modela (Semaan, 2012).

Iako je NLP često predstavljen kao podskup umjetne inteligencije, točnija kategorizacija predstavlja NLP kao interdisciplinarno područje računalnih znanosti, umjetne inteligencije i kognitivne psihologije (Kurdi, 2016). Kognitivna psihologija je iznimno važan dio obrade prirodnog jezika jer su kognitivne sposobnosti ljudi razlog nastanka, razumijevanja i učenja jezika. Osim razumijevanja i stvaranja jezika, kognitivna psihologija kao znanost fokusirana je na mentalne procese i njihovu ulogu u razmišljanju,

osjećanju i ponašanju te njihov utjecaj na percepciju, pamćenje, stjecanje znanja, rješavanje problema, kreativnost i mnoge druge sposobnosti (Kellogg, 2003). Kroz shvaćanje kako jezici nastaju, olakšano je razumijevanje nastanka gramatike, sintakse, semantike, morfologije, govora i pragmatike, a što kod obrade prirodnog jezika predstavlja polaznu točku u izgradnji modela.

Uz NLP bitno je spomenuti računalnu lingvistiku (*eng. computational linguistics*) koja omogućava da se lingvistika kao znanost istraži iz računalne perspektive. Cilj računalne lingvistike je kreirati modele jezika koji se mogu implementirati u računala kako bi se prirodni jezik mogao razumjeti i generirati (Grishman, 1986). Grishman (1986) u knjizi *Računalna lingvistika: Uvod* također navodi dva glavna dijela računalne lingvistike: **analiza prirodnog jezika** i **generiranje prirodnog jezika**, pritom dajući prednost analizi jer smatra da uspješnost sustava prirodnog jezika ponajviše ovisi o kvalitetnoj analizi inputa. Svakako treba uzeti u obzir da je generiranje prirodnog jezika nešto recentnija pojava koja tek danas postaje aktualna, što nije bio slučaj u trenutku pisanja Grishmanove knjige. Danas je postavljen snažan fokus na generiranje te primjenu prirodnog jezika kroz kreiranje izvješća, naslova slika, chatbotova, itd.

Iako slični, obrada prirodnog jezika i računalna lingvistika fokusirani su na rješavanje drukčijih problema pa je bitno razlikovati ova dva pojma. Dok je obrada prirodnog jezika usredotočena na razvijanje algoritama i modela kako bi računala razumjela, interpretirala i generirala prirodne jezike, računalna lingvistika s druge strane stavlja fokus na računalne aspekte prirodnih jezika, pritom povezujući lingvistiku, računalne te kognitivne znanosti s ciljem razumijevanja i modeliranja fenomena prirodnih jezika.

Rich, Knight & Nair (2009) navode dva glavna problema kod obrade prirodnog jezika: **obrada pisanog jezika**, korištenjem leksičkog, sintaktičkog i semantičkog poznavanja jezika, kao i potrebne informacije iz stvarnog svijeta kako bi se jezik razumio, te **obrada govornog jezika**, korištenjem prethodno navedenih potrebnih znanja, kao i dodatno znanje o fonologiji i neformalnostima u govoru za rješavanje potencijalnih dvosmislenosti. Osim što su dvosmisleni, prirodni jezici se vrlo često mijenjaju kroz vrijeme što dodatno otežava razumijevanje, analizu i stvaranje prirodnih jezika pomoću računala. Također je bitno napomenuti da korištenje modela obrade prirodnog jezika nije dovoljno za analizu, već se podaci koji ulaze u model moraju predprocesuirati kroz razne metode. Neke od tih metoda uključuju tokenizaciju, označavanje, usitnjavanje, korijenovanje i lematizaciju, a koje omogućuju točniji i standardiziraniji tekst što posljedično utječe na kvalitetu i preciznost rezultata modela (Sarkar, 2016). Čak i kada je tekst pravilno pripremljen, a model funkcionalan, NLP ne prestaje biti zahtjevan pothvat koji ovisi o mnogim faktorima,

poput raznolikosti i složenosti jezika, veličini baze podataka, nereprezentativnim podacima, prilagođavanju za područje u kojem će se model koristiti, itd.

NLP modeli najčešće koriste modele strojnog (*eng. machine learning*) i/ili dubokog učenja (*eng. deep learning*) kako bi kroz kreaciju algoritama omogućili računalu da samostalno obrađuje prirodne jezike. Ovdje je potrebno razlikovati pojmove strojnog i dubokog učenja u svrhu kasnijeg razumijevanja. Strojno učenje je podskup umjetne inteligencije koji koristeći statističke algoritme uči iz podataka i na temelju proteklih iskustava poboljšava svojstva i stvara točnija predviđanja (Mohri, Rostamizadeh, Talwalkar, 2018). Osim za obradu prirodnog jezika, strojno učenje se često koristi za prediktivnu analitiku, klasifikaciju, preporuke korisnicima, detekciju prevara, itd. S druge strane, duboko učenje je podskup strojnog učenja koje koristi algoritme, tzv. umjetne neuronske mreže, bazirane na strukturi i funkcijama ljudskog mozga, posloženim u slojeve, a koje također uče na osnovu određenih podataka, poboljšavaju svoj performans kroz učenje iz vlastitih grešaka (Brownlee, 2017). Oba tipa učenja koriste se za rješavanje sličnih problema, no modeli dubokog učenja, iako kompleksniji i zahtjevniji za izradu, mogu riješiti složenije probleme i pritom automatski učiti iz neobrađenih podataka. Modeli obrade prirodnog jezika mogu koristiti modele i strojnog i dubokog učenja, a što ponajviše ovisi o vrsti i kvaliteti podataka koje obrađuju te kompleksnosti problema koji se želi riješiti.

Problem istraživanja ovog rada usmjeren je na dohvaćanje, zatim pripremu, a potom na analizu nestrukturiranih tekstualnih podataka te njihovu obradu i transformaciju u standardizirane nazive proizvoda pomoću modela obrade prirodnog jezika napisanog u programskom jeziku Python. Ovaj programski jezik prvenstveno je odabran zbog značajnog broja biblioteka (*eng. libraries*) prilagođenih rješavanju problema pomoću modela strojnog i dubokog učenja, kao i zbog svoje fleksibilnosti, jednostavnosti, sintakse sličnoj engleskom jeziku, mogućnosti integracije s drugim tehnologijama te širokoj zajednici korisnika (Dhruv, Patel, Doshi, 2022). Python je objektno orijentiran, interpretiran i interaktivni programski jezik koji omogućuje korištenje struktura podataka na visokom nivou (Dhruv, Patel, Doshi, 2022). Python također sadržava tzv. okvire (*eng. framework*) napravljene posebno za strojno i duboko učenje, koji nisu dostupni u drugim programskim jezicima, a bez kojih bi izrada modela bila puno zahtjevnija ili nemoguća. NLP modeli prikladni su za nestrukturirane tekstualne podatke zbog razumijevanja prirodnih jezika, shvaćanja značenja i konteksta, kategorizacije te analize sentimenta, a značajnu prednost ostvaruju kroz izradu u Pythonu.

Iako je moguće koristiti već gotove modele za obradu prirodnog jezika, zbog specifičnosti područja, tipa podataka i zadržavanja sigurnosti podataka, potreban je unikatan pristup izradi modela.

Uspješna realizacija NLP modela u Pythonu omogućit će automatizaciju određenih procesa koji će utjecati na značajne uštede vremena, eliminaciju eventualnih grešaka i veće zadovoljstvo korisnika.

Osim kreiranja modela, istraživanje je također fokusirano na utjecaj umjetne inteligencije na ubrzanje i poboljšanje poslovnih procesa i poboljšanje ukupne efikasnosti poslovanja, kao i prednostima implementacije umjetne inteligencije u poslovnom kontekstu. U nastavku su prikazane prednosti implementiranja umjetne inteligencije te pregled područja organizacije na koje pozitivno utječe.

Organizacije koje implementiraju neki tip umjetne inteligencije očekuju dobit u obliku povećanja profita, širenja poslovanja, smanjenja troškova i poboljšanja poslovanja (Park, 2017; Cockburn et al., 2019; Freddi, 2018). Prema Purdy & Daugherty (2016), strojno i duboko učenje, ekspertni sustavi, obrada prirodnog jezika, prepoznavanje govora i robotika imaju najsnažniji utjecaj na poslovanje.

Nadalje, PwC (2017) predviđa da će umjetna inteligencija utjecati na rast svjetskog gospodarstva do 14% do 2030., što predstavlja rast od 15.7 trilijuna dolara. Uzimajući u obzir disruptivnost umjetne inteligencije, osim navedenih dobiti, implementacija utječe na nastanak novih poslovnih modela, što posljedično utječe na stjecanje konkurentske prednosti (Lee et al., 2019). Drugim riječima, pravovremeno implementirana umjetna inteligencija može značajno pospješiti poslovanje u raznim aspektima. S druge strane, loš pristup implementiranju može utjecati na odsutnost benefita, ali uz trošak vremena, truda i resursa (Makarius et al., 2020). Uvođenje novih tehnologija stoga treba biti prilagođeno organizaciji, cilju koji se želi postići i ljudskim resursima koji će koristiti tehnologiju.

Enholm et al. (2021) navode nekoliko područja u kojima umjetna inteligencija značajno doprinosi poslovanju.

Učinkovitost procesa. Automatizacijom ponavljajućih rutinskih zadataka, zaposlenici se mogu fokusirati na zahtjevnije aktivnosti time povećavajući svoju produktivnost (Balasundaram & Venkatagiri, 2020; Bauer & Vocke, 2019; Bytniewski et al., 2020; Finch et al., 2017). Također, korištenje umjetne inteligencije može smanjiti vrijeme potrebno za obavljanje ključnih poslovnih procesa (Coombs et al., 2020) te umanjiti stopu pogreške automatiziranjem zadataka (Wamba-Taguimdje et al., 2020).

Generiranje uvida. Umjetna inteligencija može pomoći s pronalaskom skrivenih obrazaca ponašanja u velikim količinama podataka, što utječe na efektivnije donošenje odluka baziranih na podatcima

(Jelonek et al., 2019). Iz velikog broja podataka potrebno je pronaći i iskoristiti prave informacije bitne za organizaciju te omogućiti njihovu dostupnost korisnicima točno u trenutku kada je to potrebno.

Transformacija poslovnih procesa. Implementacija umjetne inteligencije može značajno unaprijediti poslovne procese. Nosova et al. (2022) zaključuju da umjetna inteligencija može poboljšati skoro svaki proces postizanjem optimalne produktivnosti i poboljšanjem učinkovitosti, no da uvođenje treba biti rezultat pomnog proučavanja uz fokus na eventualne rizike.

Operativni učinak. Enholm et al. (2021) navode dva glavna načina na koji umjetna inteligencija utječe na operativni učinak: nastajanje novih proizvoda i usluga te poboljšanje postojećih proizvoda i usluga. Neki od primjera su kreiranje chatbotova na web stranicama koji mogu pomoći korisnicima s jednostavnijim upitima ili korištenje umjetne inteligencije u svrhu personaliziranih preporuka.

Financijski učinak. Wamba-Taguimdje et al. (2020) navode kako korištenje umjetne inteligencije u poslovanju automatizira zadatke koje bi inače obavljali razni administratori, prodavači ili izvođači radova, što predstavlja značajno smanjenje troškova za organizaciju. Također, prema Alsheibani et al. (2018) i Davenport & Ronanki (2018), organizacije koje su implementirale umjetnu inteligenciju, ostvarile su računovodstvene i financijske dobitke te povećale prihode i smanjile troškove. Ipak, za druge financijske pokazatelje poput profitabilnosti, povrata ulaganja ili bruto profitne marže, nedovoljan je broj istraživanja kako bi se ispitao utjecaj umjetne inteligencije (Enholm et al., 2021).

Učinak temeljen na tržištu. Umjetna inteligencija može poboljšati segmentaciju korisnika s obzirom na podatke postojećih, njihove navike, životni stil, preference, itd. Na sličan način se povećava zadovoljstvo postojećih korisnika kroz personalizirane ponude, bolje razumijevanje te sprječavanje eventualnih negativnih događaja (Riikinen et al., 2018). S druge strane, Castillo et al. (2020) navode kako korisnici doživljavaju interakciju s chatbotovima frustrirajućom i neefektivnom. Iz ovog je razloga bitno uzeti u obzir potrebe korisnika pri kreiranju rješenja.

Učinak na održivost. Danas je sve veći naglasak na korporativnoj održivosti, odnosno potrebi da organizacije posluju vodeći računa o ekološkim i društvenim utjecajima. Organizacije često dobrovoljno poduzimaju različite mjere kako bi odgovorile na očekivanja dionika iz različitih područja, kako bi se diferencirali među konkurencijom te kako bi na vrijeme implementirali promjene na koje će vjerojatno biti prisiljeni u budućnosti (Ioannou & Serafeim, 2021). Umjetna inteligencija može utjecati na održivost kroz smanjenje troškova i potrošnje energije te smanjenje otpada (Borges et al., 2020; Toniolo et al., 2020). Što se tiče društvenog utjecaja, veliki problem predstavlja privatnost podataka i način na

koji će organizacije osigurati sigurnost podataka, kao i eliminirati mogućnost pristranih ili diskriminirajućih rezultata.

1.2. Predmet istraživanja

U prethodnom poglavlju razrađena su kvalitativna obilježja rada koje karakterizira multidisciplinarnost područja istraživanja i koji čine osnovnu strukturu rada, a bez kojih istraživanje ne bi bilo moguće. Rad obuhvaća područja poput primjene umjetne inteligencije (Rich, 1985), strojnog učenja (Mohri, Rostamizadeh, Talwalkar, 2018) te dubokog učenja (Brownlee, 2017) u izradi modela obrade prirodnog jezika (Goldberg, 2017).

Osim tehničkih i informatičkih obilježja, rad ističe važnost ekonomskih i poslovnih aspekata koji proizlaze iz implementacije umjetne inteligencije. Primjena umjetne inteligencije u poslovnom okruženju može značajno doprinijeti efikasnosti, smanjenju troškova i povećanju konkurentnosti poduzeća. Automatizacija procesa, poput obrade prirodnog jezika, omogućava bržu i precizniju analizu velikih količina tekstualnih podataka, što rezultira boljim poslovnim odlukama i optimizacijom poslovnih procesa (Buntak, Kovačić, Mutavdžija, 2020). U kontekstu hrvatskog poslovnog okruženja, gdje je samo 9% poduzeća u 2021. koristilo neki oblik umjetne inteligencije (Eurostat, 2022), implementacija umjetne inteligencije može biti ključna za povećanje konkurentnosti i stvaranje dodane vrijednosti.

Od područja navedenih u prvom poglavlju kroz koje umjetna inteligencija doprinosi poslovanju, predmet istraživanja bit će učinkovitost procesa kroz automatizaciju zadataka, transformacija poslovnih procesa kroz ubrzanje i poboljšanje procesa standardiziranog imenovanja, učinak na financije i operativne procese te učinak na održivost kroz reduciranje potrošnje energije. Drugim riječima, predmet istraživanja temeljen je na poslovnom učinku implementacije umjetne inteligencije.

Umjetna inteligencija, konkretno kroz model obrade prirodnog jezika, može značajno poboljšati učinkovitost poslovnih procesa kroz automatizaciju zadataka. Pojednostavljeno rečeno, NLP model omogućava bržu obradu i standardizaciju naziva čime se oslobađa kapacitet zaposlenika za složenije zadatke, povećavajući produktivnost i smanjujući operativne troškove. Osim utjecaja na transformaciju poslovnih procesa, model će na sličan način utjecati na operativne procese te na smanjenje financijskih troškova i uštedu energije.

Rad također istražuje kako elementi kognitivne psihologije (Kellogg, 2003) te računalne lingvistike (Grishman, 1986) doprinose razumijevanju jezika i njegovih specifičnosti, što dalje utječe na kvalitetu podataka i efikasnost modela u poslovnom kontekstu.

Korištenjem navedenih područja te popratnih tehnika i modela, pokušat će se utvrditi konkretne ekonomske koristi i poslovni utjecaj implementiranja umjetne inteligencije u poslovanje.

Konačno, važan naglasak bit će na identifikaciji ograničenja modela obrade za vrijeme kreacije i testiranja gotovog modela. Ograničenja modela i korištenih Python biblioteka, kao i baze podataka, važni su za pravilno razumijevanje problema, kreacije funkcionalnog modela i ostvarenja cilja istraživanja. Dodatno, naglasak će biti na poslovnom aspektu implementacije modela. Uzimajući u obzir da model uspješno obrađuje tekstualne podatke i dodjeljuje standardizirane nazive, postavlja se pitanje poslovnog benefita implementacije. Drugim riječima, predmet istraživanja također uključuje istraživanje koristi modela za organizaciju kroz ubrzanje procesa, uštede vremena i novca i stjecanje konkurentske prednosti.

U sklopu istraživanja, odnosno rada na projektu, primarni fokus će biti na pisanju programskog koda u Pythonu, u alatu Visual Studio Code. Osim osnovnog paketa Python, koristit će se razne biblioteke za strojno i duboko učenje, prilagođene rješavanju predstavljenih problema. Uz to će se koristiti Google Sheets na kojem su pohranjeni svi obrađeni podatci, tj. prethodno standardizirani nazivi proizvoda, te Google Forms preko kojeg dolaze novi podatci koje je potrebno analizirati i transformirati. Podatci koji dolaze putem Google Forms automatski se spremaju u Google Sheets dokument iz kojeg ih izvlači programski kod te zatim obrađuje korištenjem modela obrade prirodnog jezika. Nakon završene transformacije, obrađeni podatci se učitavaju u prethodno spomenutu bazu podataka sadržanu u Google Sheets dokumentu.

S obzirom da je za modele obrade prirodnog jezika bitno imati trening set na bazi kojeg se model uči kako bi mogao analizirati i transformirati nove, neobrađene podatke, podatci iz Google Sheets će se prvo predprocesuirati u koristeći Excel.

1.3. Istraživačka pitanja

S obzirom na postavljeni problem te odabrani način rješavanja problema, postavljaju se istraživačka pitanja na koja će se pokušati odgovoriti u diplomskom radu. Istraživačko pitanje predstavlja središnji

dio istraživačkog procesa i upravo o njemu ovisi kvaliteta cjelokupnog projekta (Tkalac Verčić, Sinčić Ćorić, Pološki Vokić, 2010). Postavljanjem istraživačkih pitanja definira se cilj istraživanja, obuhvaća problem i predmet istraživanja. Pravilno definiranje istraživačkih pitanja jedan je od izazova ovog rada, uzimajući u obzir multidisciplinarnost, međupovezanost i međuovisnost prethodno definiranih područja. Sličan izazov prati i eksperimentalni dio rada koji kroz pisanje programskog koda objedinjuje konkretno istraživanje, eksperimente te primjenu u praksi.

Istraživačka pitanja navedena su u nastavku.

IP1: Kako primjena modela obrade prirodnog jezika u Pythonu utječe na procese analize i transformacije nestrukturiranih tekstualnih podataka u standardizirane nazive proizvoda?

Implementacijom modela obrade prirodnog jezika u Pythonu za pretvorbu tekstualnih podataka istražuju se praktične koristi s naglaskom na ubrzanje i poboljšanje poslovnih procesa i poboljšanje ukupne efikasnosti poslovanja.

IP2: Koje su prednosti i ograničenja korištenja umjetne inteligencije u procesu obrade prirodnog jezika za transformaciju tekstualnih podataka te kako se navedene tehnologije mogu integrirati u postojeće poslovne sustave?

Navedeno pitanje istražuje prednosti i izazove korištenja umjetne inteligencije, s fokusom na modele strojnog i dubokog učenja, u kontekstu obrade prirodnog jezika, te istražuje načine integracije tih tehnologija u postojeće poslovne sustave radi optimizacije procesa analize nestrukturiranih tekstualnih podataka.

IP3: Kako analiza učinkovitosti modela obrade prirodnog jezika može pružiti uvid u koristi implementacije umjetne inteligencije u poslovnom okruženju?

Analiza učinkovitosti primjene modele obrade prirodnog jezika može pomoći u razumijevanju prednosti implementacije umjetne inteligencije u poslovnom kontekstu što posljedično može utjecati na unapređenje drugih poslovnih procesa i stjecanje konkurentske prednosti.

1.4. Cilj istraživanja

Osnovni cilj istraživanja ovog rada je temeljem podataka iz primarnih i sekundarnih izvora utvrditi utjecaj implementacije modela obrade prirodnog jezika na poslovanje, odnosno utvrditi u kojoj mjeri primjena modela obrade prirodnog jezika na nestrukturirane tekstualne podatke može ubrzati i pospješiti poslovne procese i na taj način poboljšati efikasnost poslovanja i zadovoljstvo korisnika.

Kroz kreiranje i testiranje modela obrade prirodnog jezika pokušat će se pronaći tehnika ili kombinacija više tehnika koje najbolje odgovaraju zadanom problemu te na taj način evaluirati prednosti, ali i potencijalne izazove izrade modela. Svaki problem koji uključuje prirodne jezike, njihovu analizu i/ili generiranje, najčešće nema *one-size-fits-all* rješenja već odabir načina rješavanja problema ovisi o kompleksnosti samog problema, cilju koji se želi postići, kvaliteti, vrsti i kompleksnosti podataka koji se obrađuju te dostupnim drugim resursima koji će biti korišteni u projektu.

Također, jedan od ciljeva je istražiti prednosti i ograničenja implementiranja umjetne inteligencije u poslovnim procesima. Drugim riječima, donosi li primjena umjetne inteligencije veću korist od troškova, kako financijskih, tako i vremenskih, uzimajući u obzir da je kreiranje NLP modela zahtjevan pothvat koji iziskuje mnogo vremena i truda te da gotova rješenja ne mogu savršeno odgovarati zadanom problemu, tipu podataka i samoj organizaciji. Upravo veći broj različitih tehnika, alata, okvira i biblioteka vezanih za strojno i duboko učenje, iako daju veće mogućnosti i povećavaju broj različitih problema koji se mogu riješiti njihovim korištenjem, dijelom otežavaju proces pronalaska optimalnog pristupa rješavanju problema.

Konačno, cilj je procijeniti eventualni utjecaj uspješne provedbe projekta na druge poslovne procese koji mogu ostvariti korist od implementacije umjetne inteligencije. S obzirom da organizacija dosad nije implementirala nikakav oblik umjetne inteligencije, ovaj projekt bi svojom uspješnom implementacijom mogao postaviti temelje za daljnje istraživanje i primjenu naprednih tehnologija, potičući inovacije i poboljšanja u poslovnim procesima. Iako prvotne uštede vremena ili poboljšanja procesa često budu minimalni odmah nakon implementacije ili nema velike razlike s obzirom na prošli način rješavanja problema, automatizirani modeli se puno lakše skaliraju, unapređuju i prilagođavaju novonastalim promjenama i izazovima. Drugim riječima, korist implementacije modela će nastaviti rasti kroz vrijeme i unapređivati poslovne procese.

1.5. Metode istraživanja

Metodologija u znanstvenim istraživanjima obuhvaća različite postupke i pristupe koji se koriste za prikupljanje podataka i donošenje zaključaka (Zelenika, Zelenika, 2007). Istraživanje uključuje analizu primarnih i sekundarnih izvora kako bi se provjerili utjecajni faktori, izvršili eksperimenti te na taj način dali odgovori na istraživačka pitanja.

Rad slijedi strukturu koja zahtijeva teorijska istraživanja te eksperimentalni pristup kao preduvjet za donošenje zaključaka o postavljenim istraživačkim pitanjima. Teorijski dio pruža temeljno razumijevanje područja istraživanja koji će biti odrađen kroz analizu znanstvenih članaka, knjiga i drugih izvora kako bi se istražila teorija i praksa u području obrade prirodnog jezika. Također će se istraživati postojeći algoritmi, tehnike i tehnologije korištene u obradi prirodnog jezika, s naglaskom na strojno i duboko učenje te njihovu primjenu u Pythonu.

Eksperimentalni dio rada uključuje primjenu teorijskih istraživanja na izradu, implementaciju i evaluaciju modela obrade prirodnog jezika u programskom jeziku Python. Eksperimentalni dio također uključuje provjeru učinkovitosti različitih algoritama i tehnika kroz testiranje na stvarnim podatcima.

U svrhu uspješne provedbe istraživanja, korištene su sljedeće metode istraživanja (Zelenika, 2000, Tkalac Verčić, Sinčić Ćorić, Pološki Vokić, 2010; Žugalj, 1979):

- **Metoda indukcije** – koristi sustavni pristup induktivnom zaključivanju kako bi se na temelju analize specifičnih činjenica donijeli općeniti zaključci, a u radu će biti korištena sa svrhom približavanja istraživanih područja.
- **Metoda dedukcije** – uključuje proces zaključivanja koji počiva na pretpostavci općenitih načela i teorija kako bi se došlo do specifičnih zaključaka ili testiralo određenu teoriju. Metoda će se koristiti s ciljem donošenja zaključaka na temelju teorijskog i eksperimentalnog dijela rada te na taj način pokušati odgovoriti na istraživačka pitanja.
- **Metoda analize i sinteze** – metoda analize korištena je s ciljem raščlanjivanja istraživanja iz kompleksne cjeline na jednostavnije operativne elemente kako bi se bolje razumjela suština problema. S druge strane, metoda sinteze uključuje proces spajanja različitih dijelova informacija, elemenata ili koncepta kako bi se stvorila nova cjelina ili razumjelo složenije pitanje.
- **Metoda deskripcije** – metoda nužna za opisivanje, detaljno razumijevanje i dokumentiranje određenih pojava. Ova metoda koristit će se za opisivanje načina primjene

umjetne inteligencije, strojnog i dubokog učenja u izradi i implementaciji modela obrade prirodnog jezika te prednostima i nedostacima koje ta implementacija donosi.

- **Metoda klasifikacije** – metoda koja se primjenjuje u teorijskoj dijelu istraživanja kako bi se pružila nužna osnova za razumijevanje istraživačkih ciljeva i modela. Ova metoda omogućuje prijelaz od općih teorijskih koncepta prema specijaliziranim pojmovima koji su relevantni za istraživanje. U radu će se koristiti s ciljem klasifikacije pojmova umjetne inteligencije, strojnog i dubokog učenja te obrade prirodnog jezika.
- **Metoda modeliranja (praktični model)** – metoda modeliranja uključuje izradu i prikaz praktičnog modela koji može zamijeniti stvarnu pojavu i pomoću kojeg se može istraživati pojava, prikupljati podatke te donositi zaključke. U ovom radu izradit će se model obrade prirodnog jezika napisan u programskom jeziku Python, s naglaskom na korištenje biblioteka za strojno i duboko učenje.

Glavni fokus rada usmjeren je na eksperimentalni dio, odnosno izradu modela obrade prirodnog jezika u svrhu transformacije nestrukturiranih tekstualnih podataka u standardizirane nazive proizvoda. Kao što je prethodno navedeno, programski kod pisat će se u Pythonu, u alatu Visual Studio Code. Uz Python koristit će se popratne biblioteke za strojno i duboko učenje.

Od ostalih alata potrebno je spomenuti Google Sheets na kojem se nalaze već obrađeni podatci, a koji će biti korišteni kao trening set za model. Trening set je potreban kod izrade modela jer se pomoću njega model uči kako bi uspješno obradio buduće podatke. Novi podatci koje će model obraditi i transformirati se također nalaze u Google Sheets dokumentu, a u njega pristižu putem Google Forms, u ovu svrhu korišten kao alat za generiranje novih zahtjeva u obliku jednostavnog obrasca. Podatci koji dolaze putem Google Forms automatski se spremaju u Google Sheets dokument iz kojeg ih izvlači programski kod te zatim obrađuje korištenjem modela obrade prirodnog jezika.

Nakon završene transformacije, obrađeni podatci se učitavaju u prethodno spomenutu bazu podataka sadržanu u Google Sheets dokumentu. Drugim riječima, osim dijela modela koji obrađuje nestrukturirane podatke, model će sadržavati i dio koji dohvaća podatke iz Google Sheets te ih zatim obrađene vraća, a za uspješnu realizaciju koristit će se Python API (*eng. Application Programming Interface*) biblioteka. API se jednostavno definira kao način na koji dva ili više računala komuniciraju, a najčešće nisu vidljivi korisniku i ne ostvaruju interakciju s korisnicima (Biehl, 2015). API u suštini služi kao posrednik među dvjema ili više aplikacija, primjerice kao Google Maps koji je integriran u druge aplikacije.

1.6. Doprinos istraživanja

Kroz provedeno istraživanje, doprinos ovog diplomskog rada vidljiv je u nekoliko ključnih aspekata.

Ovaj rad pruža značajan doprinos u razumijevanju utjecaja primjene modela obrade prirodnog jezika u Pythonu na procese analize i transformacije nestrukturiranih tekstualnih podataka u standardizirane nazive proizvoda. Drugim riječima, istraživanje se fokusira na praktične koristi implementacije modela, istražujući kako njihova primjena može ubrzati procese i poboljšati efikasnost poslovanja.

Nadalje, istraživanje pruža uvid u prednosti i ograničenja korištenja umjetne inteligencije u procesu obrade prirodnog jezika te kako se postojeće tehnologije mogu integrirati u poslovne sustave radi optimizacije procesa analize nestrukturiranih tekstualnih podataka. Ovaj dio istraživanja doprinosi razumijevanju praktičnih izazova i mogućnosti implementacije umjetne inteligencije u stvarnom poslovnom okruženju.

Također, doprinos se ogleda u analizi učinkovitosti modela obrade prirodnog jezika koja može pružiti uvid u koristi implementacije umjetne inteligencije u poslovnom okruženju. Ovaj aspekt istraživanja pridonosi dubljem razumijevanju prednosti koje donosi primjena umjetne inteligencije u poslovnom kontekstu te kako te prednosti mogu utjecati na unapređenje drugih poslovnih procesa i stjecanje konkurentske prednosti.

Uzimajući u obzir da je obrada i transformacija navedenih nestrukturiranih podataka u standardizirane nazive vremenski osjetljiva i ključna za organizaciju, automatizacija dijela ovog poslovnog procesa predstavlja značajno bržu pomoć korisnicima što posljedično utječe na ubrzanje drugih poslovnih procesa i povećanja zadovoljstva. Doprinos je stoga vidljiv u povećanju uspješnosti poslovanja što može utjecati na druge, slične organizacije koje također mogu ostvariti korist implementiranjem umjetne inteligencije.

Konačno, ovaj rad doprinosi akademskom i praktičnom razumijevanju važnosti i potencijala primjene modela obrade prirodnog jezika u Pythonu u poslovnom kontekstu, pružajući vrijedan uvid u koristi, izazove i mogućnosti ovih tehnologija za organizacije kojima su analize nestrukturiranih tekstualnih podataka bitne za uspješno poslovanje. Dodatno, prikupljeni izlazni podaci iz modela predstavljaju osnovu za predlaganje poboljšanja postojećih i budućih modela optimiziranjem poslovnih procesa.

1.7. Struktura i sadržaj diplomskog rada

Struktura rada koncipirana je kroz sedam poglavlja koji prate predmet i problem istraživanja, a bazirani su na teorijskom i eksperimentalnom dijelu.

Uvodno poglavlje sadrži definiciju problema i predmeta istraživanja, istraživačka pitanja te cilj istraživanja do kojeg se želi doći. Uvod također sadrži opisane metode istraživanja korištene u radu te doprinos koje ovo istraživanje donosi. Naglasak je stavljen na važnost istraživanja u kontekstu suvremenih trendova u području umjetne inteligencije te njene sve veće primjene u poslovnom okruženju. Uvodni dio kreiran je po uputama Ekonomskog fakulteta u Splitu.

Drugo poglavlje rada fokusirano je na teorijsku razradu područja umjetne inteligencije. Pregledom dostupne literature utvrdit će se karakteristike područja umjetne inteligencije, obrade prirodnog jezika te njihove međusobne povezanosti. Također su definirani pojmovi strojnog i dubokog učenja te njihova uloga u kreiranju modela obrade prirodnog jezika. Osim navedenih tehničkih područja, definirat će se područja kognitivne psihologije i računalne lingvistike te njihov doprinos na razumijevanje jezika i jezičnih specifičnosti.

Treće poglavlje prezentira utjecaj implementacije umjetne inteligencije na poslovanje. Drugim riječima, predstaviti će se prednosti i ograničenja umjetne inteligencije u organizaciji, kao i područja u kojima umjetna inteligencija ostvaruje značajan doprinos. Ovo poglavlje ostvaruje bitnost kroz prijelaz među različitim područjima: umjetne inteligencije, obrade prirodnog jezika i strojnog i dubokog učenja kao tehničkih područja te utjecaja umjetne inteligencije na poslovni aspekt kao ekonomskog područja istraživanja. Nadalje, naglasak će biti na konkretnim primjerima iz prakse koji ilustriraju kako implementacija umjetne inteligencije može transformirati tradicionalne poslovne procese, poboljšati produktivnost i optimizirati operativne troškove.

Četvrto poglavlje daje dublji uvid u programski jezik Python te pregled metoda, tehnologija, biblioteka i drugih alata korištenih za izradu modela obrade prirodnog jezika. Navedena poglavlja uključuju detaljan pregled dostupne literature područja, njihovu međupovezanost i međuovisnost. Četvrto poglavlje je također eksperimentalnog karaktera, odnosno prikazuje programski kod pomoću kojeg je kreiran model. Programski kod će biti detaljno predstavljen, kao i razlozi korištenja određenih biblioteka i metoda. Također će se opisati eventualna ograničenja prilikom kreacije modela te prednosti i nedostaci pojedinih Python biblioteka. Osim programskog koda kreiranog u Pythonu, prikazat će se i ostali alati korišteni za izradu modela: Google Sheets, Google Forms i Excel. Kroz ove alate prikazat će se primarno

prikupljeni podatci i način njihove pripreme i obrade prije ulaska u model. Konačno, bit će detaljno analizirane metode evaluacije modela.

Peto poglavlje fokusirano je na rezultate istraživanja i pružanje odgovora na postavljena istraživačka pitanja. Ovo poglavlje pokušava potvrditi teorijska izlaganja diplomskog rada. Bit će predstavljeni rezultati eksperimentalne analize te će se diskutirati o njihovoj relevantnosti i implikacijama za poslovnu praksu. Također će se provesti analiza izvedivosti predloženih rješenja te će se istaknuti mogućnosti za daljnja istraživanja u ovom području.

Šesto poglavlje namijenjeno je za raspravu, odnosno sažetak i interpretaciju dobivenih rezultata s obzirom na postojeću literaturu. U ovom dijelu također se navode ograničenja istraživanja i moguća buduća unaprjeđenja. Rasprava će se fokusirati na kritičku analizu rezultata te na identifikaciju ključnih izazova i prilika za daljnje istraživanje i primjenu umjetne inteligencije u poslovnom kontekstu.

Posljednje, sedmo poglavlje, kroz zaključak objedinjuje čitavi rad te prikazuje na koji način je odgovoreno na istraživačka pitanja. Također, u zaključku će se istaknuti ključni doprinosi istraživanja te će se ponuditi smjernice za buduća istraživanja u području primjene umjetne inteligencije u poslovnom okruženju. Ovaj zaključak bit će sinteza svih prethodnih poglavlja te će ponuditi cjeloviti pogled na temu istraživanja.

Dodatno, na kraju samog rada navedena je korištena literatura te sažetak diplomskog rada na hrvatskom i engleskom jeziku.

2. UMJETNA INTELIGENCIJA U OBRADI PRIRODNOG JEZIKA

Umjetna inteligencija danas zauzima centralno mjesto među novim tehnologijama zahvaljujući svojoj sposobnosti da transformira različite industrije i poboljša svakodnevni život. Iznimno disruptivna, umjetna inteligencija je dotakla svaki aspekt života neočekivanom brzinom, a ono što se činilo kao daleka budućnost sada je postalo stvarnost. Doprinosi umjetne inteligencije vidljivi su u različitim područjima, a jedno od tih uključuje mogućnost obrade prirodnih jezika, što je dosad bio zahtjevniji čin.

2.1. Obrada prirodnog jezika

Obradu prirodnog jezika nije jednostavno definirati, uzimajući u obzir da je NLP presjek više znanosti ili se poistovjećuje s drugim, sličnim znanostima poput formalne lingvistike, računalne lingvistike, umjetne inteligencije, strojnog učenja, obrade govora i sl. (Kurdi, 2016; Eisenstein, 2018). Iako je svaka od navedenih znanosti sadržana u obradi prirodnog jezika, NLP se ne može izjednačiti s njima, već predstavlja zasebnu disciplinu. Eisenstein (2018) obradu prirodnog jezika definira kao skup metoda koje prirodni jezik čine dostupnim računalima. Na ovaj način predstavlja NLP kao sponu između prirodnih jezika i računala koji koriste umjetno stvorene računalne jezike i nisu u mogućnosti sami razumjeti prirodne jezike. Kako bi se obrada prirodnog jezika bolje shvatila, potrebno je definirati prirodne ili ljudske jezike. Jednostavno rečeno, prirodne jezike su izgradili i razvili ljudi kroz prirodnu upotrebu i komunikaciju (Sarkar, 2016). Iako su prirodni jezici oblik nestrukturiranih tekstualnih podataka, posjeduju određena pravila time olakšavajući kreiranje modela. Upravo zbog načina na koji su jezici formirani, bitno je poznavati lingvistiku jezika kako bi se pravilno izgradili modeli i time obradio prirodni jezik. Chomskyjeva (2002) definicija lingvistike uključuje proučavanje strukturalnih pravila koja upravljaju sintaksom, semantikom i fonologijom jezika, kao i istraživanje načina na koje ljudi stječu, razumiju i proizvode jezik na temelju ovih urođenih pravila. Sarkar (2016) također daje iznimnu važnost lingvistici i određenim područjima lingvistike s obzirom da se intenzivno koriste u obradi prirodnog jezika:

- **Fonetika** je proučavanje akustičkih svojstava zvukova te načina na koji ih ljudi stvaraju. Najmanja pojedinačna jedinica ljudskog govora u određenom jeziku naziva se fonem.
- **Fonologija** je proučavanje zvučnih obrazaca kako ih tumači ljudski um te koristi za razlikovanje između različitih fonema kako bi se utvrdilo koji su značajni. Fonologija obično prelazi granice proučavanja samo fonema i uključuje stvari poput naglasaka, tona i struktura slogova.

- **Sintaksa** predstavlja proučavanje rečenica, fraza, riječi i njihovih struktura, odnosno istražuje kako se riječi gramatički slažu kako bi tvorile fraze i rečenice. Sintaktički redosljed je iznimno važan jer može u potpunosti promijeniti značenje fraze ili rečenice. Temeljni problem koji sintaksa pokušava riješiti je okarakterizirati odnos između semantičkih odnosa predikat-argument i površinskih konfiguracija riječi i fraza. Drugim riječima, pokušava istražiti kako se značenja rečenica povezuju s načinom na koji su strukturirane.
- **Semantika** uključuje proučavanje značenja u jeziku, način na koji je značenje dodijeljeno riječima, frazama i rečenicama te način na koji se značenja slažu i koriste. Semantika se dijeli na leksičku i kompozicijsku semantiku.
 - o Leksička semantika: Proučavanje značenja riječi i simbola koristeći morfologiju i sintaksu.
 - o Kompozicijska semantika: Proučavanje odnosa među riječima i kombinacijama riječi te razumijevanje značenja fraza i rečenica i kako su one povezane.
- **Morfologija** je proučavanje strukture i značenja prepoznatljivih jedinica ili morfema u jeziku, a morfem predstavlja najmanju jedinicu jezika koja ima prepoznatljivo značenje. Morfemi uključuju riječi, prefikse, sufikse, itd.
- **Leksikon** uključuje proučavanje svojstava riječi i fraza korištenih u jeziku i kako one grade vokabular jezika. To uključuje vrste zvukova koji su povezani sa značenjima riječi, dijelove govora kojima riječi pripadaju te njihove morfološke oblike.
- **Pragmatika** je proučavanje kako lingvistički i nelingvistički čimbenici poput konteksta i scenarija mogu utjecati na značenje izraza ili poruke, poput zaključivanja postoje li skrivena ili neizravna značenja u komunikaciji.
- **Analiza diskursa** analizira jezik i razmjenu informacija u obliku rečenica kroz razgovore među ljudima, koji mogu biti govorni, pisani ili znakovni.
- **Stilistika** proučava jezik s naglaskom na stil pisanja, uključujući ton, naglasak, dijalog, gramatiku i tip glasa.
- **Semiologija** je proučavanje znakova, simbola i znakovnih procesa te načina na koji komuniciraju značenje. Ovo područje obuhvaća analogiju, metafore i simboliku.

Poznavanje lingvistike i određenih područja lingvistike značajno utječe na kvalitetu modela, a ovisno za što se obrada prirodnog jezika koristi, neka lingvistička područja će imati drukčiji utjecaj na model. U nastavku su navedene neke od glavnih primjena obrade prirodnog jezika prema Sarkaru (2016):

Strojno prevođenje je tehnika koja omogućava sintaktički, gramatički i semantički ispravne prijevode između bilo koja dva jezika. Alati za strojno prevođenje su u početku bili vrlo jednostavni no s napretkom tehnologije prijevodi postaju sve bolji te je moguće prevoditi veće količine teksta. Neki od primjera uključuju Google Translate i Deep L.

Sustavi za prepoznavanje govora čine najzahtjevniju primjenu obrade prirodnog jezika, a oslanjaju se na tehnike poput sinteze govora, analize, sintaktičkog raščlanjivanja i kontekstualnog zaključivanja.

Sustavi za odgovaranje na pitanja koriste NLP tehnike i pretraživanje informacija kako bi pružili odgovore na pitanja korisnika u prirodnom jeziku. Za uspjeh je potrebna velika baza znanja i efikasni sustavi za pretraživanje baze. Primjeri uključuju osobne asistente poput Siri i Cortane.

Kontekstualno prepoznavanje i razlučivanje obuhvaća razumijevanje jezika na sintaktičkoj i semantičkoj razini, uključujući aplikacije poput razlučivanja značenja riječi i rješavanja koreferencija. Koreferencija se pojavljuje kada se dva ili više pojmova ili izraza u tekstu odnose se na isti entitet, a koreferencijska rezolucija se odnosi na problem određivanja entiteta na koji se određeni pojam ili izraz odnosi (Rahman & Ng, 2011).

Sažimanje teksta uključuje smanjivanje sadržaja dokumenta kako bi se zadržale ključne točke. Postoje dvije glavne tehnike: sažimanje temeljem ekstrakcije ključnih riječi i fraza, te apstraktno sažimanje koje stvara nove rečenice sa sažetim značenjem.

Kategorizacija teksta određuje kojoj kategoriji ili klasi pripada određeni dokument na temelju sadržaja. Ova tehnika je ključna u aplikacijama poput filtera za neželjenu poštu i kategorizacije novinskih članaka.

Analiza ili rudarenje teksta koristi metode obrade prirodnog jezika, pretraživanja informacija i strojnog učenja za ekstrakciju korisnih informacija iz nestrukturiranih tekstualnih podataka. Glavne tehnike uključuju klasifikaciju teksta, klasteriranje, sažimanje, analizu sentimenta, ekstrakciju entiteta i prepoznavanje te analizu sličnosti i modeliranje odnosa.

2.2. Strojno i duboko učenje

Strojno učenje predstavlja podskup umjetne inteligencije, a definira se kao mehanizam za traženje obrazaca i ugrađivanje inteligencije u stroj kako bi mogao učiti, time implicirajući sposobnost napretka kroz iskustvo (Gollapudi, 2016). Drugim riječima, strojno učenje omogućava strojevima da riješe probleme za koje nisu nužno programirani. Prethodno spomenuto traženje obrazaca i neprestano učenje rezultiraju

predviđanjem i eventualnim rješavanjem ogromnog broja problema koje bi inače bilo nemoguće predvidjeti kroz pisanje algoritma.

Strojno učenje se može podijeliti na nadzirano (*eng. supervised*), nenadzirano (*eng. unsupervised*), polunadzirano (*eng. semi-supervised*) i učenje potkrepljenjem (*eng. reinforcement learning*) (Gollapudi, 2016).

Nadzirano učenje

Nadzirano učenje je najčešće korištena metoda strojnog učenja u primjenama obrade prirodnog jezika. U nadziranom učenju model se trenira na označenim podacima kako bi naučio predviđati ispravne izlaze za nove ulazne podatke, pri čemu uspjeh ovisi o dostupnosti dovoljno velikog broja reprezentativnih instanci ciljne funkcije (Emms & Luz, 2007). Kod nadziranog učenja model zna što treba analizirati i do kakvih zaključaka treba doći, a ulazni podatci su označeni (Gollapudi, 2016).

Nenadzirano učenje

Za razliku od nadziranog učenja, algoritam se trudi otkriti prirodne grupe unutar skupa podataka bez eksplicitne aproksimacije ciljne funkcije. Drugim riječima, model nema točno određen cilj, a ulazni podatci nisu označeni (Gollapudi, 2016). Nenadzirano učenje se koristi u rudarenju podataka, pretraživanju informacija, prepoznavanju objekata i znakova te smanjenju dimenzionalnosti za kategorizaciju teksta.

Polunadzirano učenje

Modeli polunadziranog učenja koriste i označene i neoznačene ulazne podatke kako bi se model bolje naučio, a jako je bitno da su pretpostavke za neoznačene podatke prikladne (Gollapudi, 2016).

Učenje potkrepljenjem

Učenje potkrepljenjem je tehnika učenja koja se fokusira na maksimiziranje nagrada iz rezultata. Model donosi odluke za koje se periodično prima nagrada, što može zahtijevati niz koraka prije postizanja konačnog rezultata, a cilj je izbalansirati kompromis između istraživanja i eksploatacije podataka kako bi se postigla najviša nagrada (Gollapudi, 2016). Važan aspekt je i kašnjenje u prepoznavanju nagrade, što može utjecati na proces učenja.

Duboko učenje, iako je u suštini oblik strojnog učenja, zauzima posebno mjesto zbog svojih specifičnosti. Strojno i duboko učenje imaju zajednički cilj: **predviđanje izlaznih iz ulaznih podataka**, no s obzirom da do

cilja dolaze na drukčije načine te da duboko učenje cilj ostvaruje s većom preciznošću, klasificira se kao zasebno područje. Sljedeća razlika između dubokog i strojnog učenja je način na koji koriste algoritme. Kod strojnog učenja algoritmi analiziraju podatke, uče iz njih te zatim naučeno znanje primjenjuju na buduće probleme. S druge strane, duboko učenje strukturira algoritme u slojeve, tzv. **umjetne neuronske mreže** (*eng. artificial neural network*) s više unutarnjih slojeva i specifičnih operacija filtriranja (Raaijmakers, 2022).


Umjetna neuronska mreža predstavlja pojednostavljeni model biološke neuronske mreže, a sastoji se od međusobno povezanih jedinica za obradu ili neurona (Yegnanarayana, 2009). Inspirirane su strukturom i funkcijom ljudskog mozga, a modelima dubokog učenja omogućuju da uče iz vlastitih grešaka, bez potrebe za ljudskom intervencijom (Bokka et al., 2019). Yegnanarayana (2009) u knjizi *Artificial Neural Networks* dijeli **jedinice za obradu** na dio za zbrajanje koji prima ulazne vrijednosti, važe ih i izračunava ponderirani zbroj ili aktivacijsku vrijednost nakon čega izlazni dio proizvodi signal.

Međusobna povezanost jedinica za obradu znači da ulazi u jedinicu za obradu mogu dolaziti iz izlaza drugih jedinica i/ili iz vanjskih izvora, a izlaz svake jedinice može se dati nekoliko drugih jedinica, uključujući i samu sebe (Yegnanarayana, 2009). Način na koji će jedinice biti povezane ovisi o prethodno određenoj topologiji (Krenker et al., 2011). Nadalje, opisane su operacije koje se događaju unutar umjetnih neuronskih mreža. Svaka jedinica za obradu prima ulaze i računa ponderirani zbroj, a zatim aktivacijska funkcija određuje stvarni izlaz iz ponderiranog zbroja (Yegnanarayana, 2009). Također definira **dinamiku aktivacije** koja određuje promjene aktivacijskih vrijednosti (ponderiranih zbrojeva) svih jedinica kroz vrijeme, te promjenu izlaznih vrijednosti kroz vrijeme (Yegnanarayana, 2009). Drugim riječima, dinamika aktivacije slijedi uzorak pohranjen u mreži, a kako bi se uzorak pohranio, potrebno je podesiti težine svih veza u mreži. Upravo podešavanje težina predstavlja učenje (Zou et al., 2008).

Iako mogu postojati različite vrste neuronskih mreža, osnovna arhitektura je uglavnom ista, a sastoji se od slojeva, čvorova, rubova, pristranosti i aktivacijskih funkcija (*eng. layers, nodes, edges, biases, and activation functions*) (Bokka et al., 2019).

Slojevi predstavljaju kompleksne funkcije koje procesuiraju set ulaznih podataka i težina, gdje težine kodiraju važnost informacija u neuronskoj mreži (Raaijmakers, 2022). Broj slojeva varira od modela do modela i ovisi o cilju koji se želi postići, ali postoje samo tri vrste slojeva: ulazni, skriveni i izlazni sloj. Ulazni sloj se sastoji od ulaznih podataka koji ulaze u neuronsku mrežu, a predstavlja obavezni sloj jer svaka neuronska mreža zahtijeva ulazne podatke za učenje i izvršavanje operacija kako bi mogla generirati izlaz

(Bokka et al., 2019). Svaki od slojeva povezan je s drugim slojevima pomoću **čvorova**. Iz ulaznog sloja, podatci odlaze u skrivene slojeve u kojima se obrađuju. Skriveni sloj se sastoji od aktivacijskih čvorova koji posjeduju **aktivacijsku funkciju** (Bokka et al., 2019). Tijekom treniranja, težine se procjenjuju i podešavaju između neurona, a svaki sloj vodi evidenciju o težinama za neurone koji ulaze u taj sloj (Raaijmakers, 2022). Nakon što su podatci obrađeni unutar skrivenih slojeva, a sastoji se od čvorova koji pružaju konačni ishod svih procesa i računanja (Bokka et al., 2019).



Slika 1: Neuronska mreža s dva skrivena sloja

Za obradu prirodnog jezika koriste se **rekurentne neuronske mreže** (eng. *Recurrent Neural Networks* ili *RNN*) zbog odličnih rezultata u rukovanju sekvencijalnim podacima održavanjem memorije prethodnih unosa (Garcia & Huerta, 2020). Rekurentnost predstavlja sposobnost vraćanja rezultata natrag u neuronsku mrežu, što ih čini prikladnima za probleme koji zahtijevaju razumijevanje redoslijeda i konteksta. Upravo iz tog razloga se rekurentne neuronske mreže koriste za prepoznavanje govora i zadatke obrade prirodnog jezika, kao što su sažimanje teksta, strojno prevođenje i analiza govora. Primjeri upotrebe uključuju generiranje tekstualnih naslova za slike, predviđanje vremenskih serija podataka poput prodaje ili cijena dionica te analizu sentimenta korisnika u objavama na društvenim mrežama.

S druge strane, za obradu i analizu slika i videozapisa češće se koriste **konvolucijske neuronske mreže** (eng. *Convolutional Neural Networks* ili *CNN*) (Garcia & Huerta, 2020). Primjer uključuju klasifikaciju objekata, prepoznavanje slika i uzoraka, prepoznavanje lica, detekciju objekata za autonomna vozila i identifikaciju anomalija u medicinskim slikama poput rendgenskih snimaka.

Oba tipa neuronskih mreža imaju jednaku osnovnu strukturu (ulazni, skriveni i izlazni sloj), dok su ostali dijelovi optimizirani s obzirom na različite vrste podataka koje obrađuju i zadatka koje rješavaju. Također, rekurentne i konvolucijske neuronske mreže se često koriste zajedno, primjerice kod tekstualne analize slike gdje slika treba proći kroz konvolucijsku mrežu kako bi se analizirao sadržaj na njoj, a zatim prolazi kroz rekurentnu mrežu gdje se jezik kodira i generira kako bi se dobio rezultat (Garcia & Huerta, 2020).

2.3. Kognitivna psihologija

Kognitivna psihologija zauzima bitno mjesto u obradi prirodnog jezika zbog utjecaja kognitivnih sposobnosti ljudi na stvaranje, razumijevanje i razvoj jezika. Kognitivnu psihologiju čine svi interni psihološki procesi koji sudjeluju u davanju smisla okolini i odlučivanju o prikladnim radnjama (Eysenck, 2001).

Dizajn modela umjetne inteligencije, ne samo za obradu prirodnog jezika, uvelike se oslanja na ljudske kognitivne modele, a simuliraju se ljudski mentalni procesi poput pamćenja, pažnje i kodiranja (Zhao et al., 2022). Zhao et al. (2022) smatraju da je razvoj umjetne inteligencije u kombinaciji s kognitivnom psihologijom smjer u kojem treba ići kako bi se računalima omogućila sposobnost simulacije ljudske kognitivnosti, učenja i razmišljanja te kako bi mogli prepoznati ljudske osjećaje i posljedično ostvariti dijalog i empatiju, kako s ljudima, tako i s drugim umjetnim inteligencijama.

U kontekstu obrade prirodnog jezika, proučavanje internih procesa omogućuje razumijevanje stvaranja rečenica, prepoznavanje riječi, shvaćanja konteksta, utjecaja sentimenta. Nadalje, kognitivna psihologija proučava mentalne modele i način prikazivanja informacija u umu, na taj način olakšavajući dizajn NLP modela. Osim toga proučava ljudsko pamćenje i pozornost što pomaže kod izgradnje modela za sumiranje i odgovaranje na pitanja. Konačno, kognitivna psihologija daje informacije o tome kako djeca uče jezike i nove riječi što pomaže u kreiranju algoritama koji također uče s vremenom i postaju bolji kroz iskustvo.

2.4. Računalna lingvistika

Računalna lingvistika je snažno povezana s obradom prirodnog jezika jer omogućava istraživanje lingvističke teorije korištenjem računala što posljedično utječe na izradu NLP modela i rješavanje konkretnih problema vezanih za prirodne jezike (Gliozzo & Strapparava, 2009).

Iako se računalna lingvistika prvenstveno izjednačivala s obradom prirodnog jezika, redovito nazivanom statistička obrada prirodnog jezika zbog povezanosti sa statističkim metodama, ova područja nikako nisu istovjetna (Brownlee, 2017). Nadalje, određeni autori opisuju računalnu lingvistiku kao područje s dvije strane, znanstvenom i inženjerskom stranom, a gdje obrada prirodnog jezika predstavlja inženjerski dio (Johnson, 2009). Drugim riječima, računalna lingvistika kao znanost daje teorijsku osnovu obradi prirodnog jezika koja se zatim koristi na praktičan način. Obrada prirodnog jezika računalnim lingvistima daje metode i alate potrebne za istraživanje i razumijevanje prirodnog jezika (Brownlee, 2017). No, s vremenom se računalna lingvistika izdvaja kao zasebna znanost koja se oslanja na računalne znanosti, umjetnu inteligenciju, kognitivnu psihologiju, itd.

Primjena računalne lingvistike vidljiva je u nekoliko područja, poput dohvaćanja informacija, odgovaranja na pitanja, sumiranja teksta, generiranja teksta (Ledeneva & Sidorov, 2009), razjašnjenja smisla riječi, rezoluciju koreferencije, označavanje semantičkih uloga, parafraziranje, itd. (Weikum et al. 2012).

Uz računalnu lingvistiku i općenito obradu prirodnog jezika svakako je potrebno spomenuti pojam **korpusa** (eng. *corpus*, pl. *corpora*), odnosno zbirku velikih strukturiranih jezičnih podataka, danas najčešće u elektroničkom obliku (Sarkar, 2016). Korpus može biti jednojezični ili višejezični (Sarkar, 2016). Kurdi (2016) ovim tipovima korpusa također pridodaje paralelni korpus koji sadrži verzije teksta u više različitih jezika, a koji su međusobno povezani.

Značaj tekstualnih korpusa započinje pojavom lingvistike i ljudi koji prikupljaju podatke vezane uz jezik kako bi proučavali njegova svojstva i strukturu te zatim korištenjem statističkih i kvantitativnih metoda analizirali prikupljene podatke (Sarkar, 2016). Ovi su pothvati doživjeli neuspjeh zbog manjka velikih količina podataka, a to je potaklo Chomskyja na kreiranje i formuliranje sofisticiranog jezičnog modela temeljenog na pravilima, a koji je postao temelj za izgradnju, označavanje i analizu korpusa (Sarkar, 2016).

Korpus se prije korištenja može anotirati (dodati bilješku), odnosno dodati interpretativne, lingvističke informacije elektroničkom korpusu (Leech, 1997). Potreba za anotacijom korpusa ovisi o problemu koji se rješava. Primjerice, u slučaju lingvističkog istraživanja, treniranja modela za obradu prirodnog jezika ili pretraživanja informacija, potrebno je anotirati korpus. U situacijama kad se koriste modeli nenadziranog

učenja, kada treba analizirati frekvenciju riječi, pretraživati jednostavnije riječi i slično, anotacija neće biti potrebna.

Sarkar (2016) navodi nekoliko metoda i tehnika za anotaciju korpusa.

Gramatičko ili POS označavanje koristi se za označavanje svake riječi s POS oznakom koja označava dio govora povezan s njom.

Korijen riječi je dio riječi kojem se mogu dodati različiti afiksi.

Lemme riječi koje predstavljaju kanonski ili osnovni oblik skupa riječi, a također je poznata kao osnovna riječ.

Zavisna gramatika uključuje pronalaženje različitih odnosa među komponentama u rečenicama i anotiranje zavisnosti.

Gramatika čimbenika se koristi za dodavanje sintaktičke anotacije rečenicama na temelju njihovim sastavnim dijelovima, uključujući fraze i klauzule.

Semantički tipovi i uloge uključuju različite konstituente rečenica, poput riječi i fraza, a anotirane su posebnim semantičkim tipovima i ulogama, poput mjesta, osobe, vremena, organizacije, agenta, primatelja, teme i slično.

Mnogi dostupni korpusi, poput *Brown Corpus*, *Penn Treebank*, *The British National Corpus (BNC)*, *The American National Corpus (ANC)*, *Reuters Corpus*, itd. su već anotirani i dostupni za korištenje (Sarkar, 2016). Sarkar (2016) čak navodi web, chat, elektroničku poštu i *tweetove* kao nove oblike korpusa koji su se pojavili s dolaskom društvenih mreža.

3. UTJECAJ UMJETNE INTELIGENCIJE NA POSLOVANJE

Umjetna inteligencija ostvaruje značajan učinak u različitim industrijama, a skoro da nema poduzeća na koje implementacija (ili odbijanje implementacije) neke od tehnologija umjetne inteligencije nije utjecalo u određenoj mjeri. Danas je umjetna inteligencija središnji pojam istraživanja: od toga kako utječe na potrošače, efektivnost i efikasnost poslovanja, smanjenje troškova, stjecanje konkurentske prednosti, donošenje odluka, ostvarivanje profita, itd. Iako prisutna od 50-ih godina u nekom od različitih oblika, posljednjih godina ostvaruje značajan rast kroz korištenje u poslovne i privatne svrhe, a utjecaj na svakodnevni život se ne može zanemariti. Umjetna inteligencija postala je nešto što se očekuje. Prema riječima računalnog znanstvenika Domingosa (2016): „*Umjetna inteligencija je cilj; umjetna inteligencija je planeta prema kojoj se krećemo; strojno učenje je raketa koja će nas tamo dovesti, a Big Data je gorivo.*“

Nosova et al. (2022) također dodaju kako je umjetna inteligencija novi ekonomski akcelerator, novi fenomen u modernom ekonomskom životu i novi resurs u globalnom tržišnom sustavu 21. stoljeća, a čija vrijednost svakodnevno raste. Drugim riječima, očekuje se da će umjetna inteligencija postati nezamjenjiv dio poslovanja, pogotovo s napretkom tehnologije.

Sve više organizacija implementiraju umjetnu inteligenciju (rudarenje podataka, prepoznavanje govora, obrada prirodnog jezika, prepoznavanje i obrada slika, strojno i duboko učenje, robotika, itd.), a prema podatcima Eurostata (2022), čak 30% velikih poduzeća koristi ovu tehnologiju, dok se za mala i srednja poduzeća ovaj broj kreće od 6% do 13%. Razlika među postotcima posljedica je kompleksnosti implementiranja umjetne inteligencije, visokih cijena te razlike u ekonomijama razmjera (Eurostat, 2022).

Također, utjecaj umjetne inteligencije može biti direktan ili indirektan. Neki od direktnih utjecaja uključuju automatizaciju zadaća, povećanje produktivnosti, preciznije analize, personalizaciju korisničkog iskustva, poboljšanu sigurnost i sl. Kroz direktni utjecaj, benefiti umjetne inteligencije prelijevaju se na ostala područja i aktivnosti, time ostvarujući indirektno utjecaje. Primjerice, transformacija procesa može utjecati na promjene na tržištu rada i gubitak te nastanak radnih mjesta. Sve češće korištenje ove tehnologije postavlja pitanja etike i privatnosti podataka te načina na koji će se regulirati. Nadalje, optimizacija resursa i promjena poslovnih procesa može pozitivno utjecati na probleme vezane za okoliš i održivost, ali ovu prednost je potrebno uzeti sa zadržkom. Naime, iako kroz bolje procese može pozitivno utjecati na okoliš, umjetna inteligencija svakim korištenjem troši ogromne količine energije. Naposljetku, primjećuje se utjecaj na obrazovanje i učenje kroz lakše dostupna znanja, personalizirano učenje, virtualno učenje, itd.

Implementiranje umjetne inteligencije u poslovanju donosi razne mogućnosti za unapređenje procesa, donošenje informiranih odluka i povećanje konkurentnosti na tržištu. S obzirom na neprestano razvijanje tehnologije, očekuje se još snažniji utjecaj umjetne inteligencije na poslovanje i organizacije.


Grafički prikaz 1.

Udio tvrtki koje koriste tehnologiju umjetne inteligencije, 2022

Share of companies using artificial intelligence technology, 2022



Share of companies using AI technology (e.g., machine learning, computer vision, or natural language processing) in at least one business function, out of 1,843 companies that responded to a global survey.



Data source: McKinsey & Company via AI Index Report (2022)

OurWorldInData.org/artificial-intelligence | CC BY

Note: Companies represent a range of industries, sizes, functional specialties, and tenures. To adjust for differences in response rates, the data are weighted by the contribution of each respondent's nation to global GDP.

Izvor: Our World in Dana (2022), <https://ourworldindata.org/>

Na grafu je vidljivo da otprilike polovina ispitanih organizacija primjenjuje neki od oblika umjetne inteligencije. Visoka stopa usvajanja u Sjevernoj Americi i Aziji-Pacifiku može potaknuti daljnje investiranje u istraživanje i razvoj, a samim tim veći broj inovacija, novih proizvoda i usluga, nestajanje ili mijenjanje tradicionalnih i dolazak novih poslova, povećanje produktivnosti i učinkovitosti, itd. Rast u ovim regijama može potaknuti druge regije s manjim udjelom tehnologija umjetne inteligencije u poslovanju da ulažu više kako bi poboljšali poslovanje. S druge strane, postoji mogućnost rasta nejednakosti između naprednijih i manje naprednih regija.


Grafički prikaz 2.

Udio značajnih AI sustava prema domeni

Share of notable AI systems by domain

Our World
in Data

Specific field, area, or category in which an AI system is designed to operate or solve problems.



Data source: Epoch (2024)

OurWorldInData.org/artificial-intelligence | CC BY

Note: Systems are defined as "notable" by the authors based on several criteria, such as advancing the state of the art or being of historical importance.

Izvor: Our World in Dana (2022), <https://ourworldindata.org/>

Grafikon pokazuje kako se udio umjetne inteligencije u različitim domenama mijenjao tijekom vremena. Početkom 1990-ih većina tehnologije pripadala je kategoriji *Ostalo*. S vremenom, udio u domeni *Jezik* i *Vizija* značajno raste, a pojavljuju se i nove kategorije poput *Generiranja slika* i *Multimodalni* (sistemi koji obuhvaćaju više od jednog tipa podataka, primjerice tekst, slike, audio).

Kategorija *Govor* također pokazuje stalan rast od sredine 2000-ih, što odražava napredak u tehnologijama prepoznavanja i obrade govora. Kategorija *Igre* ima stabilan udio kroz cijelo promatrano razdoblje, dok je *Biologija* relativno nova kategorija koja je počela rasti u zadnjih nekoliko godina.


Grafički prikaz 3.

Udio poslova za umjetnu inteligenciju među svim oglasima za posao

Share of artificial intelligence jobs among all job postings

Our World in Data

A job posting is considered an AI job if it requests one or more AI skills, e.g., "natural language processing", "neural networks", "machine learning", or "robotics".



Data source: Lightcast (2022) via AI Index Report (2023)

OurWorldInData.org/artificial-intelligence | CC BY

Izvor: Our World in Dana (2022), <https://ourworldindata.org/>

Ovaj grafikon prikazuje udio radnih mjesta povezanih s umjetnom inteligencijom među svim oglasima za posao u različitim zemljama od 2014. do 2022. godine. Radno mjesto se smatra AI poslom ako traži jednu ili više AI vještina, kao što su obrada prirodnog jezika, neuronske mreže, strojno učenje ili robotika.

Grafikon pokazuje kako je u Sjedinjenim Američkim Državama udio AI radnih mjesta kontinuirano rastao tijekom ovog razdoblja, dosegnuvši nešto više od 2% svih oglasa za posao u 2022. godini. Ovaj rast ukazuje na visoku potražnju za AI stručnjacima u SAD-u i naglašava važnost AI tehnologija u američkoj industriji.

Švedska također bilježi značajan porast u udjelu AI radnih mjesta, posebno od 2017. nadalje, dosegnuvši oko 1,5% u 2022. godini. Sličan trend vidljiv je i u Nizozemskoj i Njemačkoj, gdje udio AI radnih mjesta doseže oko 1% u 2022. godini. Iako Njemačka pokazuje blagi pad oko 2020., udio AI radnih mjesta ponovno raste do 2022.

Australija, Ujedinjeno Kraljevstvo, Francuska i Austrija pokazuju kontinuirani rast u udjelu AI radnih mjesta, krećući se između 0,8% i 1% u 2022. godini. Italija, Španjolska i Novi Zeland imaju niži udio AI radnih mjesta, ali svejedno pokazuju rast. Italija i Španjolska dosežu oko 0,5% do 0,7% u 2022. godini, dok Novi Zeland ima najniži udio, ali stabilan rast.

Grafikon pokazuje značajan rast udjela AI radnih mjesta u svim navedenim zemljama od 2014. do 2022. godine. Sjedinjene Američke Države prednjače u ovom rastu, dok druge zemlje, posebno u Europi, također bilježe značajan porast potražnje za AI stručnjacima. Ovi trendovi odražavaju globalni porast integracije AI tehnologija u različitim industrijama i povećanu potrebu za kvalificiranom radnom snagom u ovom području. Iz prikazanih grafova vidljiv je porast korištenja tehnologija umjetne inteligencije te utjecaj na određena područja i stvaranje novih poslova.

U nastavku je prikazan utjecaj umjetne inteligencije na različite aspekte poslovanja organizacija prema Enholm et al. (2021).

3.1. Učinkovitost procesa

Umjetna inteligencija pomaže u optimiziranju procesa poslovanja kroz brže obavljanje zadataka, automatizaciju zadataka i smanjenje eventualnih grešaka, što rezultira učinkovitijim procesima u poslovanju (Coombs et al., 2020). Kroz automatizaciju zadataka, pogotovo rutinskih, smanjuje se mogućnost pogreške, a zaposlenici se kroz značajnu uštedu vremena mogu posvetiti zadacima koji donose veću vrijednost organizaciji (Makarius et al., 2020).

Prema Nosova et al. (2022), umjetna inteligencija se može primijeniti u većini poslovnih procesa gdje omogućuje početne uvjete za poboljšanje učinkovitosti, ali da je za daljnji razvoj potreban snažan digitalni sektor u kojem se tehnologije umjetne inteligencije izravno stvaraju. Iako donosi razne benefite, Nosova et al. (2022) zaključuju kako implementacija mora biti pažljivo izvedena kako ne bi došlo do nefunkcionalnih etičkih i regulatornih odredbi te kako bi se pojačalo povjerenje u procese ljudske interakcije s umjetnom inteligencijom.

Strojno učenje kao podskup umjetne inteligencije također utječe na učinkovitost procesa. Frey & Osborne (2017) navode kako razvoj algoritama strojnog učenja omogućuje automatizaciju kognitivnih zadataka u uslužnim poslovima i poslovima s fokusom na znanje. Huang & Rust (2018) također smatraju da će neki od oblika umjetne inteligencije utjecati na uslužne poslove kroz mogućnost odrađivanja intuitivnijih i

osjetljivih zadaća. Na ovaj se način zaposlenici mogu fokusirati na kompleksnije aktivnosti dok manje i srednje zahtjevne aktivnosti obavljaju strojevi.

Nažalost, jedan od negativnih utjecaja je smanjenje broja radnika potrebnih za obavljanje zadataka. Organizacije zasigurno neće imati istu potrebu za radnicima kao prije implementiranja umjetne inteligencije, no postoji mogućnost da pozitivno utječe na stvaranje novih, više specijaliziranih radnih mjesta usko vezanih uz umjetnu inteligenciju.

3.2. Generiranje uvida

Zasigurno jedan od značajnijih utjecaja implementiranja umjetne inteligencije je mogućnost generiranja uvida. Umjetna inteligencija olakšava i ubrzava pronalaženje obrazaca i bitnih informacija u velikim količinama podataka (Mikalef & Gupta, 2021). Uzimajući u obzir da su podatci koji se danas generiraju uglavnom netransiakcijske prirode ili pripadaju nestrukturiranim podatcima, a količina podataka postaje sve veća, korištenje umjetne inteligencije za analizu podataka postaje neizostavno. Također, umjetna inteligencija će brže analizirati podatke i lakše primijetiti određene obrasce ponašanja ili anomalije nego što to mogu ljudi (Eriksson et al., 2020). Dodatno, korištenjem umjetne inteligencije za analizu podataka značajno se reduciraju greške, pogotovo ako su u pitanju ogromne količine podataka. U situacijama kada organizacije imaju pristup identičnim podatcima, jedna od njih može ostvariti bolje rezultate i postići konkurentsku prednost ako imaju kvalitetnije uvide.

Umjetna inteligencija u marketingu može doprinijeti predviđanju hoće li kupac povećati ili smanjiti potrošnju na temelju proteklih kupovina (Baesens et al., 2004). Nadalje, dobivene informacije pomažu u personalizaciji različitih stavki: preporuke na web trgovinama prilagođene korisnicima, personalizirana elektronička pošta, rješavanje eventualnih problema, itd. Navedene stavke utječu na donošenje učinkovitijih strategija, reduciranja rizika, povećanja zadovoljstva, ostvarenja profita, itd. Drugim riječima, ako donositelji odluka posjeduju detaljnije podatke, kvaliteta i brzina donošenja odluka će se povećati (Keding, 2020).

Pristup kvalitetnijim informacijama može značiti brži i bolji odgovor na promjene tržišta (Wamba-Taguimdje et al., 2020), što može rezultirati prilikama poput ulaska na nova tržišta, stvaranje novih proizvoda i usluga ili izbjegavanje određenih negativnih učinaka.

3.3. Transformacija poslovnih procesa

Inovativne i disruptivne tehnologije vrlo često utječu na transformaciju poslovnih procesa, a nerijetko i na promjenu ili nastanak novih poslovnih modela.

Nosova et al. (2022) navode različite procese u kojima umjetna inteligencija ostvaruje značajnu korist, poput prodaje gdje se može poboljšati učinkovitost korisničke službe, proširiti mogućnosti upravljanja korisničkim računima, povećati mogućnosti za cross-sell i dodatnu prodaju te poboljšati učinkovitost upravljanja potencijalnim kupcima. Dodatno navode primjer nabave gdje umjetna inteligencija može poboljšati globalno nabavljanje i integraciju dobavljača, ubrzati i poboljšati analizu te povećati učinkovitost (Nosova et al., 2022).

Nadalje, umjetna inteligencija također može utjecati na redizajn postojećih i stvaranje novih poslova, što posljedično može utjecati na promjenu procesa i organizacijske strukture (Eriksson et al., 2020). Danas je većina poslovnih procesa podložna transformaciji pod utjecajem umjetne inteligencije, primjerice automatizacijom procesa korištenjem robota, chatbotova ili virtualnih asistenata. Prethodno spomenuta personalizacija također je unaprijeđen proces koji ostvaruje benefite u povećanom angažmanu i prodaji, kao i zadovoljstvu kupaca. Nadalje, generiranje uvida koristeći umjetnu inteligenciju također djeluje na promjenu procesa kroz razne sugestije i unaprjeđenja postojećih procesa. Svaki od navedenih poslovnih procesa prolazi kroz značajne promjene s implementacijom umjetne inteligencije. Umjetna inteligencija transformira tradicionalne procese u učinkovitije, točnije i skalabilnije sustave.

3.4. Operativni učinak

Umjetna inteligencija pomaže u optimiziranju kvalitete proizvodnog sustava, a time i poboljšanju kvalitete proizvoda (Olsson & Funk, 2009; Dassisti & Giovannini, 2012; Wu et al., 2012). Jedan od načina povećanja kvalitete uključuje korištenje tzv. *fuzzy* logike temeljene na stupnjevima istine, za razliku od uobičajeno korištene Booleove logike temeljene na istini ili laži (1 ili 0) (Loureiro et al., 2021). Korištenjem *fuzzy* logike varijable poprimaju vrijednosti između 0 i 1, dajući pritom veći raspon mogućih ishoda, pogotovo kad nije moguće ponuditi precizno rješenje (Taylan & Darrab, 2012). *Fuzzy* logika ostvaruje rezultate u proizvodnoj industriji ocjenjivanjem finalnih proizvoda, primjerice 0.9 za proizvod visoke kvalitete ili 0.3 za proizvod niske kvalitete. Korištenjem tih rezultata organizacije mogu utjecati na poboljšanje kvalitete i reduciranje rizika.

Osim proizvoda, korištenjem umjetne inteligencije moguće je unaprijediti i personalizirati usluge. Enholm et al. (2021) navode primjere poput Netflixa koji koristi umjetnu inteligenciju da poboljša kvalitetu videa, Spotify koji preporučuje pjesme s obzirom na pjesme i žanrove koje su korisnici dosad slušali ili Amazon koji preporučuje različite proizvode s obzirom na dosadašnje narudžbe. Visoki stupanj personalizacije proizvoda i usluga, koji posljedično utječe na povećanje zadovoljstva korisnika, za organizacije znači uštedu vremena, veću predvidljivost i smanjenje rizika poslovanja (Loureiro et al., 2021).

Također, umjetna inteligencija se pokazala korisnom u kreiranju novih proizvoda i usluga kroz analizu velikih količina podataka i pronalaska uzoraka i prilika za ulazak na nova tržišta (Enholm et al. 2021). Primjerice, Zara koristi umjetnu inteligenciju za analizu podataka iz prodajnih mjesta, društvenih mreža i povratnih informacija kupaca kako bi predvidjela modne trendove i prilagodila svoju ponudu, a to omogućava Zari da brzo reagira na promjene u preferencijama kupaca i lansira nove proizvode koji su u skladu s trenutnim trendovima („Zara’s Comprehensive Approach to AI“, 2023).

3.5. Financijski učinak

Kao što je prethodno navedeno, implementiranje umjetne inteligencije može doprinijeti automatiziranju ili ubrzanju zadaća, što za organizacije predstavlja značajno smanjenje troškova jer se broj potrebnih radnika smanjuje (Wamba-Taguimdje et al., 2020). Rješenja umjetne inteligencije su također jeftinija, brža i manje sklona pogreškama (Castelli et al., 2016). Huang & Rust (2018) također kako umjetna inteligencija ostvaruje poseban benefit u mehaničkim i analitičkim zadaćama.

Garcia & Huerta (2020) navode nekoliko primjera u kojima umjetna inteligencija utječe na smanjenje troškova: automatizirano praćenje procesa smanjuje troškove plaća i broj potrebnih supervizora, predviđanje promjena na tržištu smanjuje potrebu za vanjskim konzultantima, korištenje modela strojnog učenja za predviđanje kvara stroja neće dovesti do zaustavljanja pogona, korištenje matematičkih modela za predikciju financijske izvedbe što umanjuje potrebu za financijskim analitičarima, itd.

Osim toga, korištenje umjetne inteligencije u prethodno spomenutim područjima može utjecati na smanjenje troškova kroz eliminaciju ili minimiziranje rizika, donošenje boljih odluka, reduciranje grešaka u proizvodnji, detaljnije i preciznije analize, itd., a što posljedično utječe, direktno ili indirektno, na smanjenje troškova i ostvarivanje viših prihoda. Nosova et al. (2022) također navode sprječavanje prijevара kroz brže otkrivanje kriminalnih aktivnosti, bolju analizu novih dobavljača, povećanje novčanih tokova kroz ubrzavanje ciklusa plaćanja, itd.

Nadalje, umjetna inteligencija može obraditi velike količine povijesnih tržišnih podataka, razaznati suptilne obrasce i predvidjeti buduće trendove (Popenici & Herr, 2017), a što omogućava donošenje informiranijih odluka.

3.6. Učinak temeljen na tržištu

Enholm et al. (2021) dijele učinak temeljen na tržištu na marketinšku učinkovitost te zadovoljstvo kupaca.

Benefiti vezani za marketing uključuju prethodno spomenut pozitivan učinak umjetne inteligencije u obliku dolaska do bitnih informacija i na taj način personaliziranju različitih aktivnosti, no osim toga, korištenje umjetne inteligencije može pomoći i kod segmentacije tržišta (Vlačić et al., 20219). Segmentacija kupaca s obzirom na različite parametre (dob, spol, preferencije, mjesto stanovanja, itd.) je polazišna točka u kreiranju marketinških strategija. Uz preciznije informacije, organizacije mogu personalizirati iskustvo korisnika te na taj način zadržati trenutne i privući potencijalne korisnike (Mishra & Pani, 2020). Verma et al. (2021) navode kako se algoritmi rudarenja teksta i strojnog učenja mogu primijeniti u sektorima kao što su bankarstvo i financije, umjetnost, maloprodaja i turizam kako bi se identificirali profitabilni segmenti kupaca. Osim toga, umjetna inteligencija će se kroz vrijeme bolje adaptirati novonastalim promjenama i zahtjevima korisnika, nego što bi to mogli ljudi (Afiouni, 2019).

Vlačić et al. (2021) također navode nekoliko primjera u kojima je umjetna inteligencija pomogla kod usklađivanja strateške orijentacije s potencijalom tržišta, poput razvoja novih proizvoda, komunikacije s kupcima, određivanja cijena, oglašavanja, upravljanja prodajom, personaliziranih mobilnih marketinških strategija, itd.

Drugi aspekt marketinške učinkovitosti, zadovoljstvo kupaca, odnosi se na stupanj zadovoljstva ponudom organizacije, što utječe na lojalnost i retenciju (Enholm et al., 2021). Kao što je prethodno spomenuto, korištenjem umjetne inteligencije jednostavnije je personalizirati proizvode ili usluge s obzirom na prošle kupnje ili preferencije kupaca (Schmidt et al., 2020). Također je brže i lakše rješavanje nastalih problema korištenjem chatbotova ili virtualnih asistenata koji korisnicima omogućuju pristup korisničkoj službi u bilo kojem trenutku. Iako možda ne mogu riješiti svaki problem ili situaciju, zasigurno mogu pomoći kod većine problema što značajno utječe na zadovoljstvo korisnika jer se problemi brže rješavaju. Prethodno je spomenut i utjecaj umjetne inteligencije na poboljšanje proizvoda i usluga, a što također utječe na veće zadovoljstvo korisnika kroz identificiranje i rješavanje ključnih problema. Implementacija umjetne

inteligencije omogućuje organizacijama da bolje razumiju potrebe svojih kupaca, pružaju im relevantnije i brže usluge i stalno unapređuju svoje ponude, što u konačnici povećava zadovoljstvo i lojalnost kupaca.

3.7. Učinak na održivost

Održivi poslovni modeli opisuju kako organizacije stvaraju, isporučuju i zadržavaju vrijednost na način koji doprinosi održivom razvoju tvrtke i društva u cjelini (Toniolo et al., 2020). Enholm et al. (2021) razlikuju dva utjecaja na održivost: ekološki i društveni utjecaj.

Ekološka održivost definira se kao zadovoljavanje potreba za resursima i uslugama sadašnjih i budućih generacija bez ugrožavanja zdravlja ekosustava (Morelli, 2011). Neka od područja koja ostvaruju benefite implementacijom umjetne inteligencije uključuju održivu poljoprivredu, bioraznolikost, korištenje obnovljivih izvora energije, smanjenje i recikliranje otpada, itd. (Nishant et al., 2020). Ge et al. (2017) navode kako predviđanje pokazatelja učinka na temelju internih i eksternih podataka može utjecati na smanjenje vremena, energije i resursa. Nadalje, Escrig et al. (2020) navode primjer čišćenja u industriji hrane i pića gdje su pomoću modela strojnog učenja ostvarili optimalno vrijeme čišćenja i na taj način smanjili potrošnju vode i kemijskih sredstava.

S druge strane, primjena umjetne inteligencije utječe na povećanje ugljičnog otiska (*carbon footprint*), a pogotovo modeli korišteni u velikim podatkovnim centrima koji analiziraju ogromne količine podataka. Potrebna energija za rad modela u određenim područjima može potpuno eliminirati benefite koje umjetna inteligencija donosi.

Društvena održivost može pomoći organizacijama da poboljšaju ugled i tržišni udio, što može doprinijeti konkurentskoj prednosti (Toniolo et al., 2020). Enholm et al. (2021) navode primjere poput osiguravanja privatnosti podataka kupaca i zaposlenika ili osiguravanje da korištenje umjetne inteligencije ne rezultira diskriminatornim radnjama ili rezultatima. Osim toga, umjetna inteligencija može učiniti radno mjesto sigurnijim kroz korištenje robota ili drugih način automatizacije što eliminira potrebu da zaposlenici koriste strojeve (Toniolo et al., 2020). Kao što je prethodno navedeno, umjetna inteligencija također može omogućiti zaposlenicima da se fokusiraju na kreativnije zadaće i zadaće koje donose veću vrijednost, što posljedično može utjecati na veće zadovoljstvo poslom.

4. EKSPERIMENTALNI DIO ISTRAŽIVANJA

Eksperimentalni dio istraživanja fokusiran je na izradu programskog koda, odnosno kreiranje modela obrade prirodnog jezika pomoću kojeg će se nestrukturirani tekstualni podatci analizirati i zatim transformirati u strukturirane podatke. Osim detaljnog pregleda programskog koda i pomoćnih alata, u nastavku je teorijski razrađen programski jezik Python i biblioteke korištene u modelu.

4.1. Programski jezik Python

Python spada među programske jezike visoke razine, za razliku od jezika niske razine (strojni ili asemblerski jezici), a glavna razlika je što program napisan u jeziku visoke razine treba biti obrađen prije izvršavanja (Downey, 2012). Prednosti jezika visoke razine uključuju lakše i brže programiranje, prenosivost, odnosno mogućnost pokretanja na različitim računalima, veća vjerojatnost da će kod biti ispravan, itd. (Downey, 2012). Filozofija Python dizajna naglašava čitljivost koda, a sintaksa omogućuje programerima izražavanje koncepata u manje linija koda (Summerfield, 2007). Najvažnija značajka Pythona je što podržava više programskih paradigmi, uključujući objektno-orijentirano, imperativno i funkcionalno programiranje ili proceduralne stilove (Srinath, 2017).

Lutz (2001) navodi glavne prednosti korištenja Pythona.

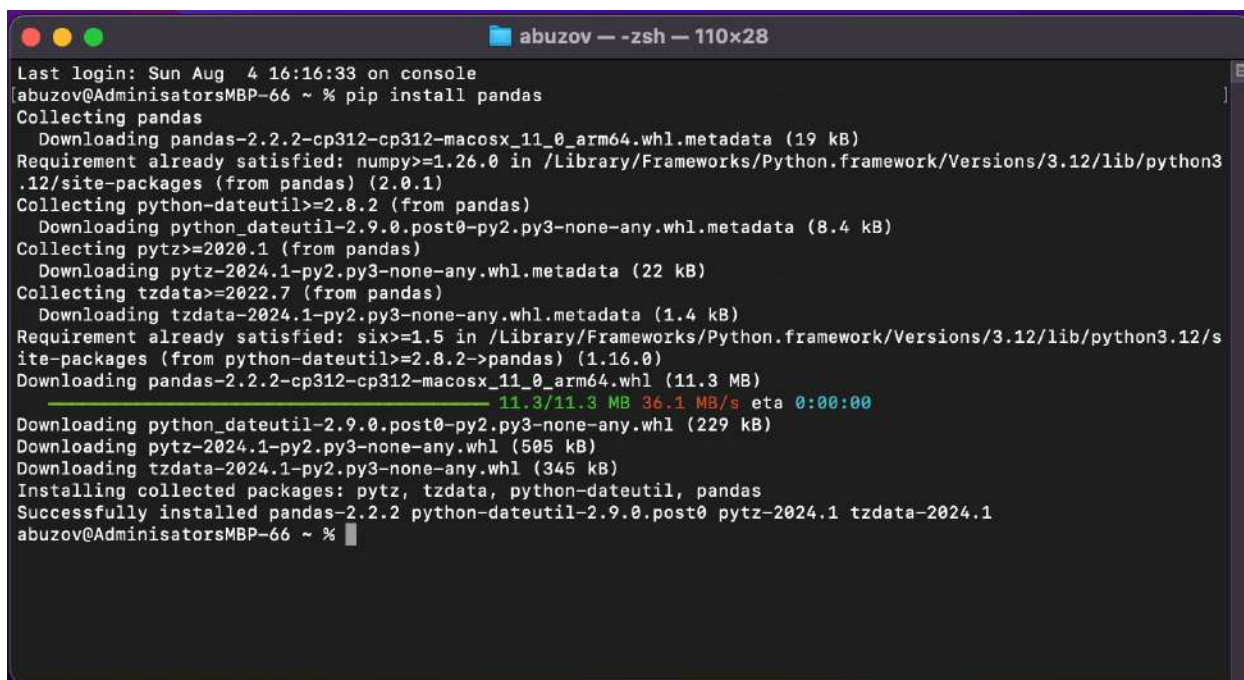
Kvaliteta. Python omogućuje olakšano pisanje softvera koji se može ponovno koristiti i održavati, a njegova jasna sintaksa i koherentan dizajn gotovo da prisiljavaju programere na pisanje čitljivog koda.

Produktivnost. Python je optimiziran za brzinu razvoja, a pošto interpreter rukuje detaljima koji se inače moraju eksplicitno kodirati u jezicima niže razine, programiranje je značajno ubrzano. U stvarnom svijetu programeri moraju kodirati i za računalo koje izvršava i za druge programere koji čitaju i održavaju. Pythonova sintaksa nalikuje pseudokodu koji se može izvršiti pa programi ostaju lako razumljivi dugo nakon što su napisani.

Prenosivost. Većina Python programa radi bez promjena na gotovo svakom računalnom sustavu koji se danas koristi. Zapravo, Python programi danas se izvršavaju na svemu, od IBM mainframe računala i Cray superračunala do prijenosnih računala i ručnih PDA uređaja. Ukratko, osnovni Python jezik i biblioteke su međuprostorno neutralne.

Integracija. Python je dizajniran za integraciju s drugim alatima. Programi napisani u Pythonu mogu se lako miješati s kodom i skriptom drugih komponenti sustava, a programi napisani u drugim jezicima mogu lako izvršavati Python skripte pozivajući C i Java API funkcije.

Nadalje, značajna prednost Pythona očituje se u velikom broju različitih biblioteka. Biblioteke sadrže određene komponente: tipove podataka, ugrađene funkcije te kolekcije modula, a povećavaju produktivnost i pojednostavljaju pisanje koda (Van Rossum, 2003). Drugim riječima, to su unaprijed napisani kodovi i funkcije koje se mogu koristiti bez da ih se mora ponovno pisati. Kao što je prethodno spomenuto, velika i aktivna zajednica korisnika dodatno olakšava korištenje Pythona kroz stvaranje novih biblioteka i unaprjeđivanje postojećih. Prije korištenja i „pozivanja“ biblioteke u kodu, potrebno ih je instalirati korištenjem tzv. naredbenog retka (eng. *command prompt*). U nastavku je prikazana instalacija biblioteke **Pandas** korištenjem naredbe **pip install pandas**. Na identičan način se instaliraju i sve druge biblioteke, a samo je potrebno znati točan naziv biblioteke.



```
abuzov — zsh — 110x28
Last login: Sun Aug  4 16:16:33 on console
abuzov@AdminisatorsMBP-66 ~ % pip install pandas
Collecting pandas
  Downloading pandas-2.2.2-cp312-cp312-macosx_11_0_arm64.whl.metadata (19 kB)
Requirement already satisfied: numpy>=1.26.0 in /Library/Frameworks/Python.framework/Versions/3.12/lib/python3.12/site-packages (from pandas) (2.0.1)
Collecting python-dateutil>=2.8.2 (from pandas)
  Downloading python_dateutil-2.9.0.post0-py2.py3-none-any.whl.metadata (8.4 kB)
Collecting pytz>=2020.1 (from pandas)
  Downloading pytz-2024.1-py2.py3-none-any.whl.metadata (22 kB)
Collecting tzdata>=2022.7 (from pandas)
  Downloading tzdata-2024.1-py2.py3-none-any.whl.metadata (1.4 kB)
Requirement already satisfied: six>=1.5 in /Library/Frameworks/Python.framework/Versions/3.12/lib/python3.12/site-packages (from python-dateutil>=2.8.2->pandas) (1.16.0)
Downloading pandas-2.2.2-cp312-cp312-macosx_11_0_arm64.whl (11.3 MB)
  11.3/11.3 MB 36.1 MB/s eta 0:00:00
Downloading python_dateutil-2.9.0.post0-py2.py3-none-any.whl (229 kB)
Downloading pytz-2024.1-py2.py3-none-any.whl (505 kB)
Downloading tzdata-2024.1-py2.py3-none-any.whl (345 kB)
Installing collected packages: pytz, tzdata, python-dateutil, pandas
Successfully installed pandas-2.2.2 python-dateutil-2.9.0.post0 pytz-2024.1 tzdata-2024.1
abuzov@AdminisatorsMBP-66 ~ %
```

Slika 2: Prikaz instalacije biblioteke Pandas korištenjem naredbenog retka

U nastavku će biti predstavljene sve korištene biblioteke u modelu obrade prirodnog jezika.

PyTorch. Ova biblioteka strojnog učenja često je korištena za aplikacije u obradi prirodnog jezika i za učenje s potkrepljenjem. Iako definirana kao biblioteka, u mnogim izvorima se koristi naziv okvir (eng. *framework*), a često se pridodaje i naziv duboko učenje. Razlog tomu je što PyTorch omogućava kreiranje dubokih neuronskih mreža te može koristiti grafičke procesore za izvođenje operacija što značajno ubrzava proces treniranja i izvođenja modela dubokog učenja (Subramanian, 2018). Dodatno, prednost PyTorch biblioteke očituje se u korištenju tenzora ili višedimenzionalnih nizova koji omogućuju modelu obrađivanje složenih vrsta podataka, poput slika, videozapisa, itd. (Stevens et al., 2020). Tensor može imati različiti broj dimenzija: skalar (0-dimenzionalni), vektor (1-dimenzionalni), matrica (2-dimenzionalni), itd.

Transformers. Ova biblioteka dizajnirana je prema standardnim NLP modelima: obrađivanje podataka, primjena modela i stvaranje predikcija, a svaki model biblioteke se sastoji od tri dijela: **tokenizator** koji sirovi tekst pretvara u tokene, **transformer** koji tokene pretvara u kontekstualne visokodimenzionalne vektorske reprezentacije (eng. *embedding*) i glavu koja koristi kontekstualne embeddinge za izradu predikcija specifičnih za zadatak (Wolf et al., 2020). Biblioteka pruža različite modele strojnog i dubokog učenja za obradu prirodnog jezika. Neki od unaprijed istreniranih modela uključuju BERT (Bidirectional Encoder Representations from Transformers), kao i GPT i T5, a svaki od modela se može dodatno trenirati i prilagoditi za određeni problem.

NumPy. Skraćeno od *Numerical Python*, ova biblioteka je prvenstveno namijenjena znanstvenom računalstvu, a kao i PyTorch, također omogućuje višedimenzionalne objekte niza te funkcije za izvođenje elementarnih operacija s nizovima ili matematičkih operacija između nizova, alate za čitanje i pisanje podataka baziranih na nizovima na disk, operacije linearne algebre, itd. (McKinney, 2012).

Gspread. Ova biblioteka namijenjena je za interakciju s Google Sheet-ovima putem Google Sheets API. Drugim riječima, gspread omogućuje pristup, modifikaciju, ekstrakciju i dijeljenje određenog Google Sheet-a.

OAuth2Client. Iako gspread biblioteka omogućava pristup Google Sheet-u, bez korištenja biblioteke OAuth2Client ne bi bilo moguće imati siguran pristup resursima, kao ni upravljati tokenima i autorizacijskim procesom.

Re. Biblioteka re pruža podršku za regularne izraze (eng. *regular expressions*, u Pythonu nazivani RegEx) koji olakšavaju prepoznavanje obrazaca i manipulaciju tekstem (Thivaharan et al., 2020). Regularni izrazi se koriste za pretraživanje, prepoznavanje i zamjenu teksta na temelju specifičnih obrazaca, što ih čini ključnim za zadatke poput provjere valjanosti podataka, parsiranja i ekstrakcije.

FuzzyWuzzy. Biblioteka FuzzyWuzzy, slično kao i dodatak za Excel, koristi se za nejasno podudaranje nizova, odnosno uspoređivanje nizova na temelju njihove sličnosti, a ne točnog podudaranja (Rao et al., 2022). Sličnost niza provjerava se između dva pojma ili fraze i daje vrijednost između 0 i 1; ako je omjer bliži 1, pojmovi su dobro usklađeni; ako je omjer bliži 0, pojmovi su nepovezani. FuzzyWuzzy je koristan u aplikacijama poput čišćenja podataka, deduplikacije i povezivanja zapisa gdje točna podudaranja možda nisu moguća zbog tipfelera ili varijacija u unosu podataka.

4.2. Programski kod

Svrha programskog koda i modela obrade prirodnog jezika je automatizirati proces zahtijevanja novih proizvoda i postavljanja potpuno novog proizvoda u slučaju kad se ne radi o duplikatu. Drugim riječima, kada je korisnicima potreban proizvod kojeg u bazi podataka nema (ili ga ne mogu pronaći), potrebno je ispuniti anketu u kojoj unose sve potrebne informacije o proizvodu kojeg žele dodati u bazu podataka. Nakon što to učine, odgovori se zabilježe u tablici kojoj programski kod pristupa, prvo provjeravajući postoji li već u bazi podataka zahtijevani proizvod, a zatim dodavajući novi proizvod ako duplikat nije pronađen.

S obzirom da informacije o proizvodima prate standardizirani način imenovanja vezan za unikatni ID te naziv proizvoda, jačinu i oblik, dodavanje novih proizvoda vrlo često može biti dugotrajan proces, pogotovo ako novih zahtjeva ima mnogo. Kombinacija Python koda, Google Forms-a i Google Sheets-a značajno ubrzava proces uz eliminiranje mogućih ljudskih pogrešaka.

Baza podataka trenutno sadrži isključivo lijekove, no moguće ju je proširiti i s drugom vrstom proizvoda.

U nastavku je prikazan i detaljno opisan korišteni programski kod za izradu modela obrade prirodnog jezika.

```
import torch
from transformers import AutoTokenizer, AutoModel
import numpy as np
import gspread
from oauth2client.service_account import ServiceAccountCredentials
import re
from fuzzywuzzy import proces
```

Prvi dio koda prikazuje pozivanje potrebnih biblioteka i njihovih komponenti za izradu navedenog modela obrade prirodnog jezika. PyTorch biblioteka korištena je za učitavanje i korištenje BERT modela, a iz biblioteke transformers uvezene su klase **AutoTokenizer** i **AutoModel** kako bi se učitao unaprijed istrenirani BERT model i tokenizator. Nadalje, biblioteka NumPy je korištena za rukovanje vektorima koji predstavljaju tekstualne podatke te za izračunavanje kosinusne sličnosti između različitih tekstualnih podataka. Gspread, kao što je prethodno spomenuto, korišten je za pristup i modifikaciju Google Sheets tablica. Usko povezana s gspread-om je biblioteka OAuth2Client iz koje se uvozi **ServiceAccountCredentials** kako bi se omogućila autentifikacija s tablicama, a time i automatizirani unos. Posljednje dvije biblioteke, re i fuzzywuzzy, korištene su u svrhu manipulacije tekstem, prepoznavanja obrazaca i pronalaženje sličnosti.

```
tokenizer = AutoTokenizer.from_pretrained('bert-base-uncased')
model = AutoModel.from_pretrained('bert-base-uncased')
```

Sljedeći dio koda učitava BERT tokenizator i model. Uloga tokenizatora je pretvoriti sirovi tekst u niz tokena koje model može obraditi, a model je zapravo neuronska mreža koja obrađuje ulazne podatke (tokene) i generira izlaz. BERT model iz tokeniziranih ulaza generira embeddinge koje sadrže informacije o kontekstu svakog tokena u odnosu na druge tokene u rečenici (González-Carvajal & Garrido-Merchán, 2021). Ovaj prethodno trenirani model dizajniran je za razumijevanje konteksta unutar rečenica, dvosmjernu obradu ili čitanje teksta s lijeva na desno i s desna na lijevo, a s obzirom da je treniran na velikim korpusima, bolje razumijeva jezične obrasce.

```
credentials = ServiceAccountCredentials.from_json_keyfile_name("/Users/abuzov/Documents/test1-417712-351258ae1c02.json")
client = gspread.authorize(credentials)
spreadsheet =
client.open_by_url("https://docs.google.com/spreadsheets/d/1Bzvtp3N7aL0PEVZFEnEwOFp5sDrSGBzKf2nIA4bwibk/edit?gid=146308459#gid=146308459")
form_responses_sheet = spreadsheet.worksheet("Form Responses")
products_sheet = spreadsheet.worksheet("Products")
```

Ovaj dio koda povezan je s prethodno opisanim `gspread` i `OAuth2Client` bibliotekama, a modelu omogućuje da korištenjem vjerodajnica servisnog računa pristupi Google API-ima u ime modela. JSON datoteka servisnom računu daje sigurnosne ključeve čime model dokazuje svoj identitet Google API-ju. Kako bi navedeni dio koda funkcionirao, potrebno je na Google Cloud Platformi kreirati servisni račun i preuzeti JSON datoteku s vjerodajnicama.

```
def encode_text(model, tokenizer, text):
    inputs = tokenizer(text, return_tensors="pt", padding=True, truncation=True, max_length=512)
    with torch.no_grad():
        outputs = model(**inputs)
    return outputs.last_hidden_state[:, 0, :].numpy()
```

Funkcija `encode_text` koristi ulazni tekst koji tokenizira, a rezultate vraća kao PyTorch tenzore. Osim toga dodaje podstavu (eng. *padding*) kako bi sve sekvence bile jednake duljine te skraćivanje (eng. *truncation*) kako bi se skratile sve sekvence dulje od maksimalne duljine. Sljedeća linija onemogućava izračunavanje gradijenta za inferenciju jer se ne trebaju računati za predikcije, a ovaj korak smanjuje potrošnju memorije i ubrzava proces. Zatim propušta tokenizirane ulaze kroz BERT model kako bi se dobili embeddingsi iz posljednjeg skrivenog sloja koji se vraćaju kao rezultat u obliku NumPy niza.

```
def format_strength(strength):
    # This function adds a space between the numerical part and the unit part
    match = re.search(r"(\d+)([a-zA-Z]+)", strength)
    if match:
        return f"{match.group(1)} {match.group(2)}"
    return strength
```

Funkcija `format_strength` formatira tekst snage proizvoda kako bi se dodao razmak između broja i mjerne jedinice (npr. 500mg u 500 mg). Prvi korak je korištenje funkcije iz `re` biblioteke koja pretražuje tekst za uzorak definiran regularnim izrazom „`r"(\d+)([a-zA-Z]+)"` gdje dio `(\d+)` pronalazi jedan ili više uzastopnih brojeva, a dio `([a-zA-Z]+)` pronalazi jedan ili više uzastopnih slova. U slučaju podudaranja formatira tekst

tako da između grupe brojeva i grupe slova umetne razmak. Ako nema podudaranja, funkcija vraća originalni tekst.

```
def normalize_form(form):
    form = form.lower().strip()
    if form in ['tab', 'tablet', 'tb', 'Tab', 'Tb']:
        return 'Tablet'
    elif form in ['cap', 'capsule', 'cp', 'Cap']:
        return 'Capsule'
    elif form in ['syr', 'syrup', 'Syr']:
        return 'Syrup'
    elif form in ['sol', 'solution', 'Sol']:
        return 'Solution'
    elif form in ['oral sol', 'Oral sol', 'Oral Sol', 'oral solution', 'Oral solution']:
        return 'Oral Solution'
    elif form in ['susp', 'suspension', 'sus', 'sp', 'Susp', 'Sus', 'Sp']:
        return 'Suspension'
    elif form in ['inj', 'injection', 'Inj']:
        return 'Injection'
    elif form in ['cream', 'cr', 'Cr']:
        return 'Cream'
    elif form in ['oint', 'ointment', 'Oint']:
        return 'Ointment'
    elif form in ['gel']:
        return 'Gel'
    elif form in ['lotion']:
        return 'Lotion'
    elif form in ['drop', 'drops', 'Drop']:
        return 'Drops'
    elif form in ['supp', 'suppository', 'Supp', 'spp', 'Spp']:
        return 'Suppository'
    elif form in ['pow', 'powder', 'pwd', 'pwr', 'Pow', 'Pwr', 'Pwr']:
        return 'Powder'
    elif form in ['gran', 'granule', 'Gran']:
```

```
    return 'Granule'  
    return form.capitalize()
```

Funkcija `normalize_form` normalizira različite unose oblika proizvoda u standardizirane oblike (npr. tab u Tablet). Osim toga, pretvara velika u mala slova i uklanja praznine, a ako nema podudaranja vraća verziju s prvim velikim slovom.

```
def correct_product_name(requested_name, existing_products):  
    product_names = [product['Product Name'] for product in existing_products]  
    closest_match, score = process.extractOne(requested_name, product_names)  
    if score > 90:  
        return closest_match  
    return requested_name
```

Funkcija `correct_product_name` koristi fuzzy podudaranje za pronalaženje najbližeg postojećeg imena proizvoda iz **Products** tablice. Metoda `process.extractOne` uspoređuje naziv zatraženog proizvoda sa svakim nazivom proizvoda u tablici, a zatim vraća najbliži proizvod koristeći skalu od 0 do 100. U kodu je postavljen prag od 90 što znači da podudaranja s rezultatom 90 ili više se prihvaćaju, dok se sličnosti ispod praga odbacuju.

```
def check_step_by_step(request, existing_products, model, tokenizer):  
    new_request_description = f"{request['Requested Name']} {request['Requested Strength']} {request['Requested Form']}"  
    new_request_embedding = encode_text(model, tokenizer, new_request_description)  
  
    similarity_threshold = 0.95  
  
    for product in existing_products:  
        product_description = f"{product['Product Name']} {product['Strength']} {product['Form']}"  
        product_embedding = encode_text(model, tokenizer, product_description)  
  
        cosine_similarity = np.dot(new_request_embedding, product_embedding.T) / \
```

```
(np.linalg.norm(new_request_embedding) * np.linalg.norm(product_embedding))
```

```
if (request['Requested Name'] == product ['Product Name'] and request['Requested Strength'] ==  
product['Strength']  
    and request['Requested Form'] == product['Form']):  
    return True, product['Product Name'], product['Strength'], product['Form']  
elif cosine_similarity > similarity_threshold:  
    return True, product['Product Name'], product['Strength'], product['Form']  
  
corrected_name = correct_product_name(request['Requested Name'], existing_products)  
  
return False, corrected_name, request['Requested Strength'], request['Requested Form']
```

Funkcija `check_step_by_step` provjerava postoji li traženi proizvod u tablici `Products`. Prvi korak je konkatenerati sve dijelove traženog proizvoda (naziv, jačina i oblik), a zatim ih pretvara u embeddinge koristeći BERT model. Nakon toga je definiran prag za kosinusnu sličnost. Nadalje, funkcija iterira kroz postojeće proizvode i računa kosinusnu sličnost između dva vektora, a koja se kreće između -1 i 1.

Sljedeći korak uključuje uspoređivanje naziva, jačine i oblika traženog proizvoda s postojećim proizvodom, a ako su potpuno isti, funkcija javlja da je pronađen duplikat. S obzirom da većina zahtjeva ne prati standardizaciju naziva, jačine i oblika, funkcija dodatno uspoređuje proizvode provjeravanjem kosinusne sličnosti. Ako je sličnost veća od definiranog praga, vratit će pronađeni slični proizvod. U slučaju da nije pronađen duplikat, funkcija kreira novi naziv pomoću fuzzy podudaranja, dodaje jačinu i oblik.

```
def generate_product_id(products_sheet):  
    all_ids = products_sheet.col_values(1)[1:]  
    if all_ids:  
        last_id = max(all_ids)  
        last_number = int(last_id.split('-')[-1]) + 1  
        new_id = f"MED-{{str(last_number).zfill(5)}}"  
    else:  
        new_id = "MED-00001"  
    return new_id
```


Funkcija `generate_product_id` generira novi ID na temelju postojećih. Prvi korak je pregledati sve ID-jeve i doći do posljednjeg, a zatim povećati taj broj za jedan i na taj način kreirati novi ID za novi proizvod. U slučaju da nema nijednog ID-ja, postavlja novi ID na prvu vrijednost.

```
existing_products = products_sheet.get_all_records()
```

Navedena linija koda služi za dohvaćanje svih postojećih proizvoda iz Products tablice.

```
for i, row in enumerate(form_responses_sheet.get_all_records(), start=2):
    if row['Status'] != "":
        continue
    new_product_id = ""
    is_duplicate, name, strength, form = check_step_by_step(row, existing_products, model, tokenizer)

    if is_duplicate:
        status = 'Duplicate'
        duplicate_id = ""
        for product in existing_products:
            if product['Product Name'] == name and product['Strength'] == strength and product['Form'] == form:
                duplicate_id = product['Product ID']
                break
    else:
        status = 'New request'
        strength = format_strength(strength)
        form = normalize_form(form)
        new_product_id = generate_product_id(products_sheet)

    new_product_row = [new_product_id, name, strength, form]
    products_sheet.append_row(new_product_row)
    print(f"Added new product to Products tab: {new_product_row}")
```

Navedeni dio koda iterira kroz sve proizvode u Form Responses tablici koja zapisuje sve zahtjeve za novim proizvodima korištenjem ankete izrađene u Google Forms. Kroz iteraciju prvo pregledava polje u stupcu Status, a ako polje nije prazno znači da je taj redak već obrađen pa prelazi na sljedeći redak. Također poziva funkciju `check_step_by_step` koja provjerava je li zahtijevani proizvod duplikat ili ne. Ako zaista pronade duplikat, postavlja polje u stupcu Status na Duplicate, a polja koja označavaju ID proizvoda, naziv, jačinu i oblik popunjava s informacijama o pronađenom proizvodu.

U slučaju da funkcija ne pronade duplikat, postavlja status na New Request i koristeći funkcije `format_strength`, `normalize_form` i `generate_product_id` dodjeljuje novom proizvodu sve potrebne informacije. Osim toga, dodaje novi redak u Products tablicu sa svim informacijama o novom proizvodu. Naposljetku, isprintat će poruku da je dodan novi proizvod te navesti ID proizvoda, kao i naziv, jačinu i oblik.

```
form_responses_sheet.update_cell(i, 5, status)
    form_responses_sheet.update_cell(i, 6, new_product_id if status == 'New request' else duplicate_id)
    form_responses_sheet.update_cell(i, 7, name)
    form_responses_sheet.update_cell(i, 8, strength)
    form_responses_sheet.update_cell(i, 9, form)
```

Konačno, zadnji dio koda ažurira polja u tablici Form Responses s informacijama o proizvodu duplikatu ako je pronađen duplikat, odnosno s informacijama o novom proizvodu u slučaju da duplikat nije pronađen.

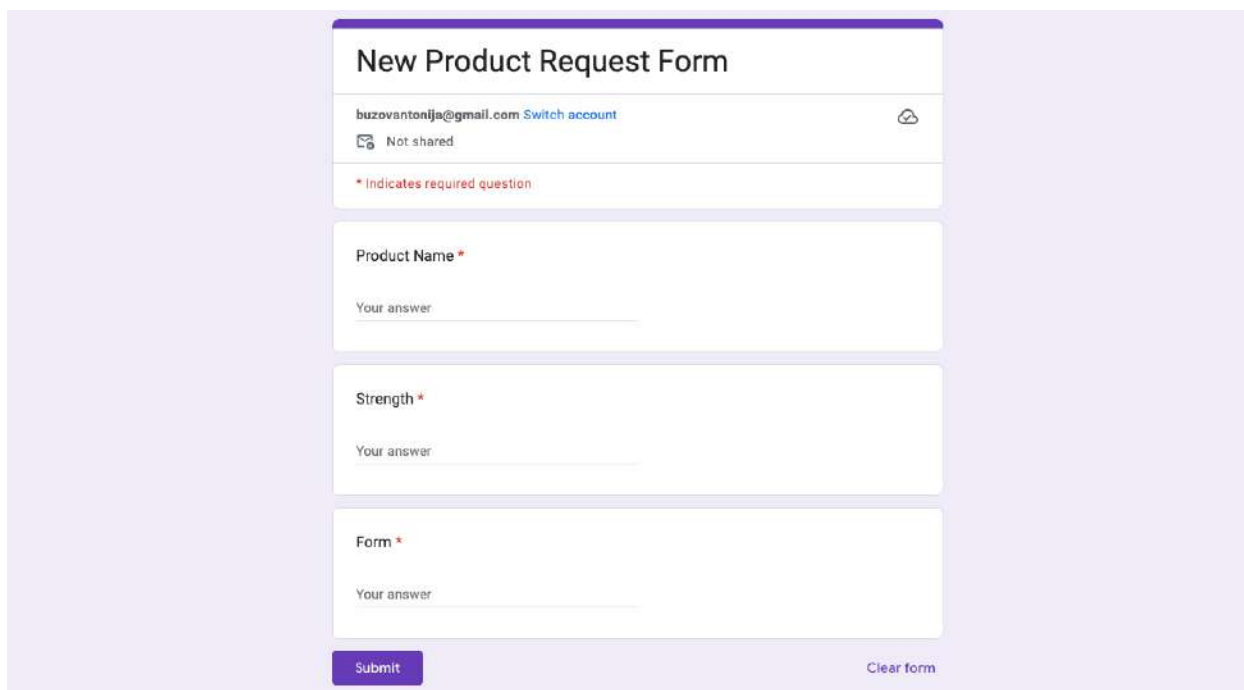
4.3. Pomoćni alati

Osim prethodno opisanog programskog koda u Pythonu, za model obrade prirodnog jezika također su korišteni alati Google Forms i Google Sheets.

Google Forms je korišten u svrhu kreiranja ankete koju korisnici ispunjavaju kako bi zatražili novi proizvod koji im je potreban, a kojeg u postojećoj bazi podataka nema. Anketa se sastoji od tri pitanja:

- **Product Name:** korisnici upisuju generičko ime lijeka, primjerice ibuprofen umjesto Neofen
- **Strength:** korisnici upisuju jačinu lijeka, npr. 500mg
- **Form:** korisnici upisuju oblik lijeka u kojem dolazi, npr. tableta ili kapsula

U nastavku je prikazan izgled ankete **New Product Request Form**.

The image shows a web form titled "New Product Request Form". At the top, it displays the user's email "buzovantonija@gmail.com" with a "Switch account" link and a "Not shared" status. A red asterisk indicates required questions. The form contains three text input fields: "Product Name *", "Strength *", and "Form *", each with a "Your answer" placeholder. At the bottom, there are "Submit" and "Clear form" buttons.

Slika 3: Izgled ankete New Product Request Form

Nakon što korisnici ispune anketu, poslani odgovori se spremaju u Google Sheets dokument **Product Requests**, u tablicu **Form Responses**. Odgovori se uvijek spremaju prema pravilu najnoviji odgovori se nalaze na vrhu tablice u drugom retku (prvi redak rezerviran je za naslove stupaca). Form Responses tablica sastoji se od devet stupaca:

- **Timestamp:** Automatski dodjeljuje vrijeme kada su odgovori zabilježeni.
- **Requested Name:** Naziv zahtijevanog proizvoda naveden u anketi.
- **Requested Strength:** Jačina zahtijevanog proizvoda navedena u anketi.
- **Requested Form:** Oblik zahtijevanog proizvoda naveden u anketi.
- **Status:** Status proizvoda koji se dodjeljuje nakon što se model pokrene. U slučaju da je zahtijevani proizvod pronađen u Products tablici, odnosno da već postoji u bazi podataka, dodjeljuje mu se status **Duplicate**. Ako proizvod nije pronađen, dodjeljuje mu se status **New Request**.
- **Final Product ID:** Unikatan ID koji se dodjeljuje novom proizvodu nakon što je kreiran. U slučaju da je proizvod duplikat, kopira se Product ID iz Products tablice.

- **Final Product Name:** Konačni naziv lijeka koji model dodjeljuje proizvodu.
- **Final Strength:** Konačna jačina lijeka koju model dodjeljuje proizvodu.
- **Final Form:** Konačan oblik lijeka koji model dodjeljuje proizvodu.

U nastavku su prikazane Form Responses i Products tablice.

1	A	B	C	D	E	F	G	H	I
Timestamp	Requested Name	Requested Strength	Requested Form	Status	Final Product ID	Final Product Name	Final Strength	Final Form	
2	7/23/2024 17:01:11	Abacavir	300mg	Tab	New request	MED-00939	Abacavir	300 mg	Tablet
3	7/29/2024 12:50:33	Pantoprazole + domperidon	20 + 10 mg	Tab	New request	MED-00937	Pantoprazole + Domperidon	20 + 10 mg	Tablet
4	7/29/2024 12:16:13	Amoxicillin + Clavulanate	500+125mg	Tab	Duplicate	MED-00005	Amoxicillin + Clavulanate	500 + 125 mg	Tablet
5	7/29/2024 12:07:56	Nitazoxanide+ofloxacin	500mg+200mg	Tab	New request	MED-00933	Nitazoxanide + Ofloxacin	500 + 200 mg	Tablet
6	7/29/2024 12:07:25	Rabeprazole sodium + domperidone	20mg + 10mg	Tab	New request	MED-00934	Rabeprazole sodium + Domperidone	20 + 10 mg	Tablet
7	7/29/2024 12:06:47	Raltegravir	400mg	Tab	New request	MED-00935	Raltegravir	400 mg	Tablet
8	7/29/2024 12:06:29	Ritonavir	100 mg	Tab	New request	MED-00936	Ritonavir	100 mg	Tablet
9	7/26/2024 11:24:05	Methylphenidate	36mg	Tab	New request	MED-00930	Methylphenidate	36 mg	Tablet
10	7/26/2024 11:23:48	Methylphenidate	27mg	Tab	New request	MED-00931	Methylphenidate	27 mg	Tablet
11	7/26/2024 11:23:35	Methylphenidate	18mg	Tab	New request	MED-00932	Methylphenidate	18 mg	Tablet
12	7/26/2024 11:18:55	Misoprostol	25mcg	Tab	New request	MED-00926	Misoprostol	25 mcg	Tablet
13	7/26/2024 11:18:35	Elemental iron	35mg	Tab	New request	MED-00927	Elemental iron	35 mg	Tablet
14	7/26/2024 11:18:10	Zinc sulfate	50mg	Tab	New request	MED-00928	Zinc sulfate	50 mg	Tablet
15	7/26/2024 11:17:48	Paracetamol	400mg	Tab	New request	MED-00929	Paracetamol	400 mg	Tablet
16	7/26/2024 11:11:26	Cefalexin	125 mg/5ml	Suspension	Duplicate	MED-00083	Cefalexin	125 mg/5 ml	Suspension
17	7/26/2024 11:10:50	Acetaminophen	160mg/5ml	Oral sol	Duplicate	MED-00062	Acetaminophen	160 mg/5 ml	Oral Solution
18	7/26/2024 11:08:42	Amoxicillin	500 mg	Cap	Duplicate	MED-00007	Amoxicillin	500 mg	Capsule
19	7/26/2024 11:03:11	Diazoxide	100mg/ml	Susp	New request	MED-00922	Diazoxide	100 mg/ml	Suspension
20	7/26/2024 11:02:07	Cholecalciferol	3500 IU	Oral drops	New request	MED-00923	Cholecalciferol (Vit D3)	3500 IU	Oral Drops
21	7/26/2024 11:01:16	Etoposide	25mg	cap	New request	MED-00924	Etoposide	25 mg	Capsule
22	7/26/2024 11:00:53	Flunitrazepam	2mg	Tab	New request	MED-00925	Flunitrazepam	2 mg	Tablet
23	7/14/2024 18:34:06	Atorvastatin	10mg	Tab	Duplicate	MED-00010	Affcalcitol	1 mcg	Capsule
24	7/14/2024 18:32:49	Cefixime	400mg	Tab	Duplicate	MED-00014	Cefixime	400 mg	Tablet
25	7/14/2024 18:32:08	Acetaminophen	500mg	Tab	Duplicate	MED-00001	Fluoxetine	20 mg	Capsule
26	7/14/2024 18:19:31	Amoxicillin	500 mg	Cap	Duplicate	MED-00007	Amoxicillin	500 mg	Capsule
27	7/14/2024 18:13:59	Vitamin C	500 mg	Cap	Duplicate	MED-00919	Vitamin C	500 mg	Capsule
28	7/14/2024 18:06:49	Amoxicillin	500mg	Cap	Duplicate	MED-00007	Amoxicillin	500 mg	Capsule
29	7/14/2024 17:39:43	Ethravirine	100 mg	Tab	Duplicate	MED-00756	Ethravirine	100 mg	Tablet
30	7/14/2024 17:37:45	Diosmin	600 mg	Tab	Duplicate	MED-00874	Diosmin	600 mg	Tablet
31	7/14/2024 17:17:50	Captopril	25 mg	Tab	Duplicate	MED-00129	Captopril	25 mg	Tablet
32	7/14/2024 16:35:08	Amoxicillin	500mg	Cap	Duplicate	MED-00007	Amoxicillin	500 mg	Capsule
33	7/14/2024 16:32:20	Etoposide	100mg	Cap	Duplicate	MED-00895	Etoposide	100 mg	Capsule
34	7/14/2024 16:18:19	Haloperidol	2.5mg	tab	Duplicate	MED-00901	Haloperidol	2.5 mg	Tablet

Slika 4: Izgled tablice Form Responses

Crveno označenom lijeku je model dodijelio krivi proizvod, iako je prepoznao da je lijek duplikat. O ovome će više riječi biti u poglavlju Rezultati istraživanja.

	A	B	C	D
1	Product ID	Product Name	Strength	Form
2	MED-00001	Acetaminophen	500 mg	Tablet
3	MED-00002	Acetylsalicylic Acid	500 mg	Tablet
4	MED-00003	Albendazole	200 mg	Tablet
5	MED-00004	Aminophylline	100 mg	Tablet
6	MED-00005	Amoxicillin + Clavulanate	500 mg + 125 mg	Tablet
7	MED-00006	Amoxicillin	250 mg	Capsule
8	MED-00007	Amoxicillin	500 mg	Capsule
9	MED-00008	Amoxicillin	500 mg	Tablet
10	MED-00009	Atenolol	50 mg	Tablet
11	MED-00010	Atorvastatin	10 mg	Tablet
12	MED-00011	Azithromycin	250 mg	Tablet
13	MED-00012	Carbamazepine	200 mg	Tablet
14	MED-00013	Cefalexin	500 mg	Tablet
15	MED-00014	Cefixime	400 mg	Tablet
16	MED-00015	Cetirizine HCl	10 mg	Tablet
17	MED-00016	Chlorpromazine HCl	100 mg	Tablet
18	MED-00017	Ciprofloxacin	500 mg	Tablet
19	MED-00018	Clarithromycin	500 mg	Tablet
20	MED-00019	Clomipramine	75 mg	Tablet
21	MED-00020	Diclofenac potassium	50 mg	Tablet
22	MED-00021	Doxycycline	100 mg	Tablet
23	MED-00022	Fluconazole	150 mg	Tablet
24	MED-00023	Fluoxetine	20 mg	Capsule
25	MED-00024	Folic Acid	5 mg	Tablet
26	MED-00025	Furosemide	20 mg	Tablet
27	MED-00026	Haloperidol	10 mg	Tablet
28	MED-00027	Hyoscine Butylbromide	10 mg	Tablet
29	MED-00028	Hyoscine Butylbromide	5 mg/5ml	Syrup
30	MED-00029	Ibuprofen	100 mg/5ml	Syrup
31	MED-00030	Ibuprofen	100 mg/5ml	Suspension

+ ☰ Form Responses ▾ Main ▾ Products ▾

Slika 5: Izgled tablice Products

U tablici Products pohranjeni su različiti lijekovi s unikatnim ID-jevima te nazivima, jačinama i oblicima. Baza podataka trenutno sadrži blizu tisuću lijekova, no taj će se broj s vremenom i novim zahtjevima povećavati. Novi lijekovi se dodaju na dno tablice, nakon zadnjeg postojećeg lijeka.

Tablica se sastoji od 4 stupca:

- **Product ID:** Unikatni ID dodijeljen svakom lijeku koji se sastoji od dva dijela. Prvi dio je riječ MED koja govori da se radi o lijekovima, a drugi dio označava sekvencijalni broj koji počinje od 00001. Iako baza podataka sadrži isključivo lijekove pa je oznaka MED praktički nepotrebna, postoji mogućnost da se baza u budućnosti proširi s drugim tipovima proizvoda, pa je na ovaj način

ostavljen prostor da se kreiraju nove kategorije. Dodavanje različitih kategorija modelu će olakšati i ubrzati pretraživanje proizvoda te dodavanje novih.

- **Product Name:** Naziv dodijeljen lijeku koji ne mora biti unikatan. Razlika među proizvodima istih naziva odredit će se pomoću jačine i oblika lijeka. Ime lijeka se uvijek piše velikim slovom, a ako lijek sadrži više od jednog aktivnog sastojka, svaki od njih se također piše velikim slovom, npr. Amoxicillin + Clavulanate.
- **Strength:** Jačina lijeka dodijeljena proizvodu, uvijek se piše s razmakom između broja i mjerne jedinice.
- **Form:** Oblik lijeka dodijeljen proizvodu, uvijek se piše velikim slovom.

	A	B	C	D
1	Product ID	Product Name	Strength	Form
920	MED-00919	Vitamin C	500 mg	Capsule
921	MED-00920	Atenolol	100 mg	Tablet
922	MED-00921	Febuxostat	160 mg	Tablet
923	MED-00922	Diazoxide	100mg/ml	Suspension
924	MED-00923	Cholecalciferol (Vit D3)	3500 IU	Oral Drops
925	MED-00924	Etoposide	25 mg	Capsule
926	MED-00925	Flunitrazepam	2 mg	Tablet
927	MED-00926	Misoprostol	25 mcg	Tablet
928	MED-00927	Elemental iron	35 mg	Tablet
929	MED-00928	Zinc sulfate	50 mg	Tablet
930	MED-00929	Paracetamol	400 mg	Tablet
931	MED-00930	Methylphenidate	36 mg	Tablet
932	MED-00931	Methylphenidate	27 mg	Tablet
933	MED-00932	Methylphenidate	18 mg	Tablet
934	MED-00933	Nitazoxanide + Ofloxacin	500 + 200 mg	Tablet
935	MED-00934	Rabeprazole sodium + Domperidone	20 + 10 mg	Tablet
936	MED-00935	Raltegravir	400 mg	Tablet
937	MED-00936	Ritonavir	100 mg	Tablet
938	MED-00937	Pantoprazole + Domperidon	20 + 10 mg	Tablet
939	MED-00938	Abacavir	300 mg	Tablet
940	MED-00939	Abacavir	300 mg	Tablet
941				
942				
943				
944				
945				
946				
947				
948				
949				
950				

+ ☰ Form Responses ▾ Main ▾ Products ▾

Slika 6: Izgled tablice Products

5. REZULTATI ISTRAŽIVANJA

U ovom poglavlju bit će predstavljeni rezultati eksperimentalne analize te će se diskutirati o njihovoj relevantnosti i implikacijama za poslovnu praksu te na taj način dati odgovore na istraživačka pitanja. Također će se provesti analiza izvedivosti predloženih rješenja te će se istaknuti mogućnosti za daljnja istraživanja u ovom području.

Eksperiment će se uraditi na način da se prvo ispuni anketa u kojoj će se zatražiti različiti lijekovi, neki od njih duplikati, a neki potpuno novi proizvodi koji nisu sadržani u bazi podataka. Na taj način će se ustanoviti kako model obrade prirodnog jezika funkcionira u različitim situacijama. Također će se prilikom ispunjavanja ankete neke lijekove pisati malim slovima, ponekad s greškama u nazivu, kako bi se model dodatno istrenirao na različite situacije. Osim naziva, jačina i oblik će se također pisati različito od standardiziranog imenovanja.

Potrebno je spomenuti da NLP modeli nisu savršeni te da je nemoguće uvijek dobiti zadovoljavajuće rezultate upravo zbog kompleksnosti koja prati prirodni jezik. Modeli bazirani na umjetnoj inteligenciji se treniraju sa svakim pokretanjem modela, kao i s rastom i kvalitetom baze podataka iz kojih se uče, a zaključak je da će takvi modeli s vremenom postati sve bolji i davati bolje rezultate. Drugim riječima, modele umjetne inteligencije treba percipirati kao živo biće koje se uči kroz rad i teži boljim rezultatima.

S obzirom da su modeli strojnog i dubokog učenja vrlo često zahtjevni za računala, čak i kad je sam model jednostavnije prirode, obrada novih zahtjeva obrađivat će se iz više puta, odnosno neće se odmah obraditi svi zahtjevi nego do deset zahtjeva po jednoj obradi. Svaka od obrada trajala je dvije do tri minute.

Dodatno, model neće obrađivati već obrađene zahtjeve, a uvjet za to je ispunjena ćelija u stupcu Status.

U nastavku su prikazani različiti zahtjevi i rezultati obrade tih zahtjeva u kojima je prag sličnosti postavljen na 0.95, tj. 95%. Osim ovog praga, prikazat će se i rezultati obrade s pragom sličnosti 0.85.

Timestamp	Requested Name	Requested Strength	Requested Form	Status
7/14/2024 18:34:06	Atorvastatin	10mg	Tab	Duplicate
7/14/2024 18:32:49	Cefixime	400mg	Tab	Duplicate
7/14/2024 18:32:08	Acetaminophen	500mg	Tab	Duplicate
7/14/2024 18:19:31	Amoxicillin	500 mg	Cap	Duplicate
7/14/2024 18:13:59	Vitamin C	500 mg	Cap	Duplicate
7/14/2024 18:06:49	Amoxicillin	500mg	Cap	Duplicate
7/14/2024 17:39:43	Etravirine	100 mg	Tab	Duplicate
7/14/2024 17:37:45	Diosmin	600 mg	Tab	Duplicate
7/14/2024 17:17:50	Captopril	25 mg	Tab	Duplicate
7/14/2024 16:35:08	Amoxicillin	500mg	Cap	Duplicate
7/14/2024 16:32:20	Etoposide	100mg	Cap	Duplicate
7/14/2024 16:18:19	Haloperidol	2.5mg	tab	Duplicate
7/14/2024 16:16:40	Febuxostat	160mg	Tab	New request
7/14/2024 16:02:49	Acetaminophen	500 mg	Tablet	Duplicate
6/29/2024 19:38:55	Vitamin C	500mg	Cap	New request
6/29/2024 18:49:22	Atenolol	100mg	Tab	New request

Slika 7: Zahtjevi za novim proizvodima – Grupa 1

Prva grupa zahtjeva za novim lijekovima uglavnom sadržava lijekove koji već postoje u bazi podataka, a s ciljem da se analizira sposobnost modela u prepoznavanju duplikata. Dodatno, većina zahtijevanih jačina i oblika lijekova nije napisana prema standardiziranom imenovanju kako bi se provjerilo koliko dobro model funkcionira u dodavanju standardiziranih jačina i oblika definiranih u programskom kodu.

Final Product ID	Final Product Name	Final Strength	Final Form
MED-00010	Alfacalcidol	1 mcg	Capsule
MED-00014	Cefixime	400 mg	Tablet
MED-00001	Fluoxetine	20 mg	Capsule
MED-00007	Amoxicillin	500 mg	Capsule
MED-00919	Vitamin C	500 mg	Capsule
MED-00007	Amoxicillin	500 mg	Capsule
MED-00756	Ethravirine	100 mg	Tablet
MED-00874	Diosmin	600 mg	Tablet
MED-00129	Captopril	25 mg	Tablet
MED-00007	Amoxicillin	500 mg	Capsule
MED-00895	Etoposide	100 mg	Capsule
MED-00901	Haloperidol	2.5 mg	Tablet
MED-00921	Febuxostat	160 mg	Tablet
MED-00001	Acetaminophen	500 mg	Tablet
MED-00919	Vitamin C	500 mg	Capsule
MED-00920	Atenolol	100 mg	Tablet

Slika 8: Rezultati obrade zahtjeva – Grupa 1

Rezultati obrade zahtjeva Grupe 1 skoro su potpuno točni, s iznimkom crveno označenog lijeka. Za sve ostale lijekove model je točno prepoznao kada je riječ o duplikatu, a kada o novom zahtjevu. Za duplikate je kao rezultat vratio točne lijekove s njihovim ID-jevima, nazivima, jačinama i oblicima, a novim zahtjevima točno dodao navedene informacije. Također su ispravljene greške kod zahtijevanih jačina i oblika, npr. 400mg u 400mg i tab u Tablet. Naposljetku su novi lijekovi dodani na dno Products tablice.

Što se tiče pogrešno obrađenog lijeka, model je prvo točno zaključio da se radi o duplikatu, no umjesto da kao rezultat vrati zahtijevani lijek Atorvastatin jačine 10 mg u obliku tablete, vraća lijek Alfacalcidol jačine 1 mcg u obliku kapsule.

Razlog za ovakav rezultat može biti velika sličnost u imenu lijeka za koji je model zaključio da je identično, bez dodatnog provjeravanja jačine i oblika lijeka. Problem može nastati kad model krivo zaključi da je lijek duplikat, iako nije, bez obzira koji lijek vrati kao rezultat.

Timestamp	Requested Name	Requested Strength	Requested Form	Status
7/26/2024 11:24:05	Methzphenidate	36mg	Tab	New request
7/26/2024 11:23:48	Methylphenidate	27mg	Tab	New request
7/26/2024 11:23:35	Mwthylphenidate	18mg	Tab	New request
7/26/2024 11:18:55	Misoprostol	25mcg	Tab	New request
7/26/2024 11:18:35	Elemental iron	35mg	Tab	New request
7/26/2024 11:18:10	Zinc sulfate	50mg	Tab	New request
7/26/2024 11:17:48	Paracetamol	400mg	Tab	New request
7/26/2024 11:11:26	Cefalexinn	125 mg/5ml	Suspension	Duplicate
7/26/2024 11:10:50	Acetaminophen	160mg/5ml	Oral sol	Duplicate
7/26/2024 11:08:42	Amoxicillin	500 mg	Cap	Duplicate
7/26/2024 11:03:11	Diazoxide	100mg/ml	Susp	New request
7/26/2024 11:02:07	Cholecalciferol	3500 IU	Oral drops	New request
7/26/2024 11:01:16	Etoposide	25mg	cap	New request
7/26/2024 11:00:53	Flunitrazepam	2mg	Tab	New request

Slika 9: Zahtjevi za novim proizvodima – Grupa 2

Druga grupa zahtjeva za lijekovima uglavnom sadržava lijekove kojih nema u postojećoj bazi podataka. Kao i kod Grupe 1, nazivi, jačine i snage su kod nekih lijekova namjerno napisani krivo ili ne prateći standardizaciju imenovanja.

Final Product ID	Final Product Name	Final Strength	Final Form
MED-00930	Methylphenidate	36 mg	Tablet
MED-00931	Methylphenidate	27 mg	Tablet
MED-00932	Methylphenidate	18 mg	Tablet
MED-00926	Misoprostol	25 mcg	Tablet
MED-00927	Elemental iron	35 mg	Tablet
MED-00928	Zinc sulfate	50 mg	Tablet
MED-00929	Paracetamol	400 mg	Tablet
MED-00083	Cefalexin	125 mg/5 ml	Suspension
MED-00062	Acetaminophen	160 mg/5 ml	Oral Solution
MED-00007	Amoxicillin	500 mg	Capsule
MED-00922	Diazoxide	100 mg/ml	Suspension
MED-00923	Cholecalciferol (Vit D3)	3500 IU	Oral Drops
MED-00924	Etoposide	25 mg	Capsule
MED-00925	Flunitrazepam	2 mg	Tablet

Slika 10: Rezultati obrade zahtjeva – Grupa 2

Model je točno prepoznao duplikate i kao rezultat vratio odgovarajuće lijekove, a za nove lijekove je točno odabrao naziv, jačinu i snagu te ih prilagodio standardizaciji imenovanja. Također su dodijeljeni unikatni ID-jevi, a na kraju su svi novi lijekovi dodani u Products tablicu.

Zanimljivo je kako kod prva tri lijeka: Methzlpheidate, Methzlpheidate i Mwthylphenidate postoji vrlo očita gramatička greška, no model pravilno prepoznaje da se u sva tri slučaja radi o lijeku Methylphenidate.

Nadalje, model je prepoznao da je lijek Cholecalciferol zapravo Cholecalciferol (Vit D3) pa mu sukladno tomu dodjeljuje ovaj naziv. S obzirom da navedeni lijekovi već postoje u bazi podataka, postoji mogućnost da je model shvatio da se radi o tim lijekovima i donio pravilan zaključak na temelju tih informacija, no također je moguće da je razlog tomu prethodno istrenirani BERT model koji razumije kontekst.

Timestamp	Requested Name	Requested Strength	Requested Form	Status
8/10/2024 12:01:28	donepezil	2.5mg	tab	New request
8/10/2024 12:00:50	ibuprofen	100mg/5ml	susp	Duplicate
8/10/2024 12:00:01	glycine	200mg	tab	New request
8/10/2024 11:58:31	Barium sulphate	75%	susp	New request
8/10/2024 11:58:04	Telmisartan	120mg	tab	New request
7/29/2024 17:01:11	Abacavir	300mg	Tab	New request
7/29/2024 12:50:33	Pantoprazole + domperidon	20 + 10 mg	Tab	New request
7/29/2024 12:16:13	Amoxicillin + Clavulanate	500+125mg	Tab	Duplicate
7/29/2024 12:07:56	Nitazoxanide+ofloxacin	500mg+200mg	Tab	New request
7/29/2024 12:07:25	Rabeprazole sodium + domperidone	20mg + 10mg	Tab	New request
7/29/2024 12:06:47	Raltegravir	400mg	Tab	New request
7/29/2024 12:06:29	Ritonavir	100 mg	Tab	New request

Slika 11: Zahtjevi za novim proizvodima – Grupa 3

Kod sljedeće grupe također je većina zahtjeva za nove proizvode, a svi osim jednog rezultata su zadovoljavajući. Kao i kod prethodnih grupa, nazivi lijekova, jačina i oblika nisu napisani prema standardiziranom imenovanju.

Final Product ID	Final Product Name	Final Strength	Final Form
MED-00943	Donepezil	5 mg	Tablet
MED-00030	Ibuprofen	100mg/5ml	Suspension
MED-00944	Glycine	200 mg	Tablet
MED-00945	Barium sulphate	75%	Suspension
MED-00946	Telmisartan	120 mg	Tablet
MED-00939	Abacavir	300 mg	Tablet
MED-00937	Pantoprazole + Domperidon	20 + 10 mg	Tablet
MED-00005	Amoxicillin + Clavulanate	500 mg + 125 mg	Tablet
MED-00933	Nitazoxanide + Ofloxacin	500 mg + 200 mg	Tablet
MED-00934	Rabeprazole sodium + Domperidone	20 mg + 10 mg	Tablet
MED-00935	Raltegravir	400 mg	Tablet
MED-00936	Ritonavir	100 mg	Tablet

Slika 12: Rezultati obrade zahtjeva – Grupa 3

Kod točnih rezultata model je dobro prepoznao situacije u kojima se proizvod sastoji od dva lijeka, a samim time i dvije jačine, npr. Pantoprazole + Domperidon, 20 + 10 mg. Nazivi su standardizirani pa tako svaki lijek započinje velikim slovom, a jačine imaju razmak između broja i mjerne jedinice.

Rezultat koji nije točan je zahtijevani lijek Donepezil jačine 2.5mg u obliku tablete. Iako točno prepoznaje da se radi o novom lijeku, kao rezultat vraća lijek koji postoji u bazi podataka, a koji je istog naziva i oblika, ali krive jačine (5 mg umjesto 2.5 mg). Dodjeljuje mu i novi ID: MED-00943, iako identičan lijek postoji pod ID-jem MED-00537. Pretpostavka je da model teže percipira lijekove kojima jačina ima decimalnu točku.

Timestamp	Requested Name	Requested Strength	Requested Form	Status
8/10/2024 12:30:39	Levetiracetam	100 mg/ml	syr	Duplicate
8/10/2024 12:30:10	Dihydrocodeine phosphate	60 mg	tab	New request
8/10/2024 12:29:49	Hydroxyurea	125mg	cap	New request
8/10/2024 12:29:33	Sitagliptin	50mg	tab	Duplicate
8/10/2024 12:29:16	Cefixime + clavulanate	50 mg + 100 mg	suspension	Duplicate
8/10/2024 12:28:17	Ergocalciferol (Vit D2)	20,000 IU	capsule	New request
8/10/2024 12:04:36	amoxicillim	500mg	tab	Duplicate
8/10/2024 12:04:23	Amoxicillin	60 mg/5ml	powder for suspension	New request
8/10/2024 12:03:26	Cholecalciferol (Vit D3)	2000 IU	oral drops	Duplicate
8/10/2024 12:02:43	Diclofenac potassium	100mg	tab	New request
8/10/2024 12:01:50	magnesium	400mg	oral sol	New request

Slika 13: Zahtjevi za novim proizvodima – Grupa 4

Četvrta grupa također sadrži skoro savršene rezultate. Model je kombinacije duplikata i novih zahtjeva vrlo dobro obradio, osim jednog lijeka.

Final Product ID	Final Product Name	Final Strength	Final Form
MED-00169	Levetiracetam	100 mg/ml	Syrup
MED-00947	Dihydrocodeine phosphate	60 mg	Tablet
MED-00948	Hydroxyurea	125 mg	Capsule
MED-00804	Sitagliptin	50 mg	Tablet
MED-00833	Cefixime + Clavulanate	50 mg + 31.25 mg	Suspension
MED-00949	Ergocalciferol (Vit D2)	20,000 IU	Capsule
MED-00007	Amoxicillin	500 mg	Tablet
MED-00940	Amoxicillin	60 mg/5ml	Powder for Suspension
MED-00248	Cholecalciferol (Vit D3)	2000 IU	Oral Drops
MED-00941	Diclofenac potassium	100 mg	Tablet
MED-00942	Magnesium	400 mg	Oral Solution

Slika 14: Rezultati obrade zahtjeva – Grupa 4

Kod točnih rezultata ponovno dobro prepoznaje duplikate vraćajući odgovarajuće lijekove, a za nove zahtjeve pravilno dodjeljuje novi ID, naziv, jačinu i oblik. Lijek kojeg nije točno obradio je Cefixime + clavulanate, jačine 50 mg + 100 mg u obliku suspenzije kojeg prepoznaje kao duplikat i vraća rezultat Cefixime + Clavulanate, jačine 50 mg + 31.25 mg u obliku suspenzije. Zahtijevani lijek nije duplikat već novi zahtjev, a razlog krivog prepoznavanja može bit dvostruki naziv i jačina.

Sljedeća grupa lijekova obrađena je s pragom sličnosti 0.85.

Timestamp	Requested Name	Requested Strength	Requested Form	Status
8/10/2024 15:47:31	Haloperidol	1 mg/ml	oral drops	Duplicate
8/10/2024 15:46:42	Pyrantel pamoate	100 mg/ml	susp	Duplicate
8/10/2024 15:46:14	Activated charcoal	250mg	tab	Duplicate
8/10/2024 15:45:09	Carbocysteine	2%	syr	Duplicate
8/10/2024 15:44:45	Diltiazem HCl	120mg	cap	Duplicate
8/10/2024 15:44:25	Paracetamol	240 mg/5 ml	susp	Duplicate
8/10/2024 15:43:30	Gliclazide	30mg	tablet	New request
8/10/2024 15:42:28	Lamotrigine	200mg	tab	Duplicate
8/10/2024 15:42:09	Fluoxetine	20mg	cp	Duplicate
8/10/2024 15:41:42	Acetaminophen	500mg	tab	Duplicate

Slika 15: Zahtjevi za novim proizvodima – Grupa 5

Kod pete grupe s pragom sličnosti 0.85, model je većinu lijekova krivo prepoznao, ili kao duplikate ili kao nove zahtjeve. Također je za lijekove duplikate uglavnom dodijelio potpuno nepovezane lijekove.

Prvi zahtjev, Haloperidol jačine 1 mg/ml u obliku oralnih kapi, novi je zahtjev koji model krivo prepoznaje kao duplikat te mu dodjeljuje lijek Acetaminophen. Slična situacija je i kod druga dva lijeka: Pyrantel pamoate i Paracetamol. Acetaminophen je prvi lijek u bazi podataka i s obzirom da je prag sličnosti spušten na 0.85, modelu je većina stvari slična pa tako odmah u prvom lijeku nalazi odgovarajući rezultat, makar kriv. Kada nije riječ o Acetaminophenu, kao rezultat redovito vraća Acetylsalicylic Acid, drugi lijek u bazi. Drugim riječima, čak i manja promjena praga sličnosti rezultira vrlo lošim rezultatima.

Final Product ID	Final Product Name	Final Strength	Final Form
MED-00001	Acetaminophen	500 mg	Tablet
MED-00001	Acetaminophen	500 mg	Tablet
MED-00658	Activated charcoal	250 mg	Tablet
MED-00002	Acetylsalicylic Acid	500 mg	Tablet
MED-00002	Acetylsalicylic Acid	500 mg	Tablet
MED-00001	Acetaminophen	500 mg	Tablet
MED-00950	Gliclazide	30 mg	Tablet
MED-00881	Dutasteride	500 mcg	Capsule
MED-00023	Fluoxetine	20 mg	Capsule
MED-00001	Acetaminophen	500 mg	Tablet

Slika 16: Rezultati obrade zahtjeva – Grupa 5

U nastavku slijede odgovori na istraživačka pitanja.

IP1: Kako primjena modela obrade prirodnog jezika u Pythonu utječe na procese analize i transformacije nestrukturiranih tekstualnih podataka u standardizirane nazive proizvoda?

S obzirom na rezultate eksperimenta, uzimajući pritom samo one s pragom sličnosti 0.95, može se zaključiti da model obrade prirodnog jezika napisan u Pythonu vrlo pozitivno utječe na proces analize i transformacije nestrukturiranih tekstualnih podataka. Od 53 zahtjeva, samo su 3 zahtjeva bila pogrešna. Korištenje prethodno treniranog BERT modela iz biblioteke transformers pokazalo se kao dobar izbor. Model je, uz pomoć drugih funkcija, uspješno prepoznao duplikate, varijacije u nazivima, jačinama i oblicima te pogrešno napisane riječi, a zatim ih ispravno transformirao u standardizirane nazive. Nadalje, model vrlo dobro razumije kontekst, što mu daje dodatnu prednost pred drugim modelima, a pogotovo pred manualnom obradom nestrukturiranih tekstualnih podataka.

Dodatno, model obrade prirodnog jezika omogućuje brzu i efikasnu obradu većih količina nestrukturiranih tekstualnih podataka, što bi inače zahtijevalo ručnu intervenciju, a time i puno veći gubitak vremena i učestalije pogreške.

Konačno, prednost modela je mogućnost učenja što omogućuje modelu da sa svakom novom obradom zahtjeva daje sve točnije rezultate, ne samo za lijekove, već i za druge tipove proizvoda.

IP2: Koje su prednosti i ograničenja korištenja umjetne inteligencije u procesu obrade prirodnog jezika za transformaciju tekstualnih podataka te kako se navedene tehnologije mogu integrirati u postojeće poslovne sustave?

Prednosti korištenja umjetne inteligencije očituju se u efikasnijoj i efektivnijoj obradi tekstualnih podataka čime se oslobađa kapacitet zaposlenika za složenije zadatke, povećavajući produktivnost i smanjujući operativne troškove. Bez modela obrade prirodnog jezika, zaposlenici bi nove zahtjeve manualno obrađivali, time trošeći vrijeme na proces koji može biti automatiziran.

No, umjetna inteligencija sa sobom može donijeti nedostatke, najčešće u obliku kompleksne implementacije i održavanja. Iako model u ovom radu spada pod jednostavnije te obrađuje samo lijekove,

za potrebe veće organizacije bi model trebao biti nešto složeniji i pritom moći obrađivati i druge tipove proizvoda.

Nadalje, model uz Python koristi Google Forms i Google Sheets što neke organizacije ne koriste, a to znači da bi se čitavi model trebao prilagoditi alatima koje organizacija koristi. Drugim riječima, integracija bi bila moguća, no za veće organizacije kompleksnija i s višim troškovima.

Također se postavlja pitanje ugljičnog otiska. Iako ovaj model nije na razini ChatGPT-a ili Gemini-ja, svako korištenje umjetne inteligencije zahtijeva velike količine energije. Naposljetku, postoje rizici s privatnošću i sigurnošću jer, iako podatci o lijekovima nisu osjetljive prirode, preko njih je moguće doći do onih koji jesu.

IP3: Kako analiza učinkovitosti modela obrade prirodnog jezika može pružiti uvid u koristi implementacije umjetne inteligencije u poslovnom okruženju?

Analiza učinkovitosti NLP modela omogućuje mjerenje točnosti i preciznosti modela, kao i uštedu vremena korištenjem modela umjesto manualne obrade. Kroz analizu je moguće otkriti pogreške i nedostatke modela te s tim informacijama raditi na unaprjeđenju.

Nadalje, u proces obrade nestrukturiranih tekstualnih podataka uključeni su i korisnici koji šalju zahtjeve za novim lijekovima. Osim točnosti, vrlo im je bitna brzina obrade zahtjeva koja se može poboljšati korištenjem automatiziranog procesa, a to znači bolje korisničko iskustvo.

Konačno, modeli obrade prirodnog jezika se mogu mijenjati prema potrebi organizacije. Također su skalabilni pa mogu vrlo jednostavno pratiti povećanje zahtjeva, što bi bez modela zahtijevalo više radne snage, a time bi se povećali i troškovi.

6. RASPRAVA

Rezultati modela pokazali su visoku točnost, s 50 točno obrađenih zahtjeva od ukupno 53, što ukazuje na pouzdanost i efikasnost korištenih NLP modela u obradi nestrukturiranih podataka i njihovu pretvorbu u standardizirane nazive proizvoda. Korištenje modela obrade prirodnog jezika za proces obrade nestrukturiranih tekstualnih podataka pokazala se kao izuzetno korisno, pružajući značajne uštede vremena. Kada bi se model implementirao u organizaciju, osim vremena, uštedjeli bi se resursi te smanjila potreba za radnom snagom. Kroz detaljnu analizu učinkovitosti modela, identificirane su prednosti, ali i izazovi povezani s implementacijom umjetne inteligencije u poslovne procese.

Potrebno je napomenuti da je riječ o jednostavnijem modelu obrade prirodnog jezika i korištenju besplatnih alata Google Sheets i Google Forms, koji bez obzira na to ostvaruje dosta dobre rezultate obrade zahtjeva. Također, treba uzeti u obzir kompleksnost baze podataka koja se sastoji isključivo od generičkih lijekova vrlo specifičnih naziva, a koji nisu dio razgovornog jezika i značajno otežavaju obradu teksta i shvaćanje konteksta, pogotovo što nazivi lijekova nemaju konkretna značenja kao što to imaju riječi kuća ili pas. Kompleksnost dodatno potvrđuje i prag sličnosti od 95% koji je zbog specifičnih naziva vrlo osjetljiv na promjene pa čak i manja promjena čini model lošim. Naime, mijenjanje praga sličnosti s 0.95 na 0.85, što je i dalje vrlo visok prag, rezultiralo je užasavajućim rezultatima gdje je model skoro pa uvijek vraćao prva dva lijeka iz baze podataka kao rezultat, makar nisu imali nikakvih sličnosti s traženim proizvodima.

U slučaju kada bi se model unaprijedio i koristio s drugim, jačim pomoćnim alatima, moguće je da bi ostvarivao skoro pa savršene rezultate u vrlo kratkom vremenu. Naravno, za ovaj pothvat, osim stručnjaka, potrebna su i kompleksnija računala koja mogu pokrenuti složene modele.

Iako model dobro funkcionira i daje zadovoljavajuće rezultate, nikako nije bez ograničenja, a prvenstveno su vidljiva u nedostatku povratnih informacija koje bi model mogao dobivati nakon obrade zahtjeva, a koje bi pomogle s učenjem i treniranjem modela te posljedično boljim rezultatima. Dodatno, model se može prilagoditi tako da, osim lijekova, obrađuje i druge tipove proizvoda, primjerice proizvode za kućanstvo, automobilske dijelove, elektroniku, itd. Također je bitno navesti ograničenje u načinu na koji se model pokreće, što je trenutno manualno, no kada bi model stalno radio i obrađivao zahtjeve onaj trenutak kad pristignu, dobio bi se potpuno automatizirani proces.

Konačno, iako model nije savršen, sa zadovoljavajućim rezultatima obrađuje zahtjeve, prepoznaje greške i shvaća kontekst, a implementacija u poslovni proces je zasigurno pozitivan pothvat koji donosi više prednosti nego nedostataka.

7. ZAKLJUČAK

Implementacija modela obrade prirodnog jezika i umjetne inteligencije predstavlja ključni korak prema modernizaciji i optimizaciji poslovnih procesa. Većina današnjih alata za različite primjene nudi mogućnost korištenja umjetne inteligencije za brži rad, različite analize, preporuke i mnogo drugih funkcionalnosti. Drugim riječima, **umjetna inteligencija je sadašnjost**. Iako sa sobom ne donosi isključivo pozitivne mogućnosti, odgađanje korištenja alata umjetne inteligencije u poslovne svrhe značit će gubitak za organizacije u različitim sferama, kao što je bio slučaj s digitalizacijom poslovanja. No to ne znači da umjetnu inteligenciju treba prihvatiti u bilo kojem obliku, već ju prilagoditi za potrebe organizacije, a na umu imati troškove implementacije i potrošnju energije. Važno je također naglasiti etičke implikacije, jer iako umjetna inteligencija nudi ogromne mogućnosti, primjena mora biti odgovorna, uzimajući u obzir potencijalne rizike kao što su pristranosti u modelima, privatnost podataka i utjecaj na radnu snagu. Integracija umjetne inteligencije mora biti usmjerena na stvaranje vrijednosti ne samo za organizacije, već i za društvo u cjelini.

Također je bitno napomenuti kompleksnost NLP modela, kao i međupovezanost s drugim znanostima i tehnologijama. Modeli obrade prirodnog jezika nisu isključivo inženjerske prirode već je za kvalitetan dizajn modela potrebno poznavati dodatna područja, poput računalne lingvistike i kognitivne psihologije koja će omogućiti pravilniju izradu modela. Prirodni jezici su ljudske tvorevine koje se često mijenjaju i za čije je razumijevanje potrebno puno iskustva, razumijevanja konteksta i pravilnog zaključivanja, sve što bi i NLP model trebao imati za zadovoljavajuću obradu.

Osim toga, uspjeh u implementaciji umjetne inteligencije ovisit će o sposobnosti organizacija da neprestano uče, prilagođavaju se i inoviraju. Ove tehnologije nisu statične već se razvijaju zajedno s potrebama i očekivanjima korisnika. Stoga će kontinuirano ulaganje u istraživanje, razvoj i edukaciju biti ključno za dugoročni uspjeh u sve konkurentnijem globalnom tržištu.

Zaključno, primjena umjetne inteligencije i obrade prirodnog jezika zasigurno poboljšava učinkovitost i točnost obrade podataka i na taj način postavlja temelje za buduće inovacije u načinu na koji se poslovni procesi mogu optimizirati i skalirati. Iako su potrebna daljnja istraživanja i unaprjeđenja, trenutno postignuti rezultati već sada jasno ukazuju na značajan potencijal tehnologija u poslovnom okruženju, čineći ih nezamjenjivim dijelom modernih poslovnih strategija.

LITERATURA

KNJIGE

Biehl, M. (2015). API Architecture. API-University Press.

Boden, M. A. (1996). Artificial Intelligence. Academic Press, Inc.

Bokka, K. R., Hora, S., Jain, T., Wambugu, M. (2019). Deep Learning for Natural Language Processing: Solve your natural language processing problems with smart deep neural networks. Packt Publishing Ltd.

Brownlee, J. (2017). Deep Learning for Natural Language Processing: Develop Deep Learning Models for your Natural Language Problems. Machine Learning Mastery.

Chomsky, N. (1957). Syntactic Structures.

Cockburn, Iain M., Rebecca Henderson, and Scott Stern. (2019) "The Impact of Artificial Intelligence on Innovation." The Economics of Artificial Intelligence: An Agenda. Pp: 115-152.

Downey, A. B. (2012). Think Python. O'Reilly Media, Inc.

Eisenstein, J. (2018). Natural Language Processing. MIT Press.

Eysenck, M. W. (2001). Principles of Cognitive Psychology. Psychology Press.

Freddi, Daniela. (2018) "Digitalisation and employment in manufacturing." AI & Society 33(3): 393-403.

Goldberg, Y. (2017). Neural Network Methods for Natural Language Processing. Morgan &

Claypool. Grishman, R. (1986). Computational Linguistics: An Introduction. Cambridge University

Press. Hunt, E. B. (2014). Artificial Intelligence. Academic Press, Inc.

Gliozzo, A., Strapparava, C. (2009). Semantic Domains in Computational Linguistics. Springer Science & Business Media, Jul 31, 2009

Gollapudi, S. (2016). Practical Machine Learning. Packt Publishing Ltd.

Kellogg, R. T. (2003). Cognitive Psychology. Sage Publishing.

Krenker, A., Bešter, J., Kos, A. (2011). Introduction to the Artificial Neural Networks. u Suzuki, K. (Ur.). Artificial Neural Networks - Methodological Advances and Biomedical Applications (str. 3-19). Intech Open Access Publisher.

- Kurdi, M. Z. (2016): Natural Language Processing and Computational Linguistics 1. ISTE Ltd, Wiley & Sons, Inc.
- Lutz, M. (2001). Programming Python. O'Reilly Media, Inc.
- McKinney, W. (2012). Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython. O'Reilly Media, Inc.
- Mohri, M., Rostamizadeh, A., Talwalkar, A. (2018). Foundations of Machine Learning, second edition. The MIT Press.
- Park, Sang-Chul. (2017) "The Fourth Industrial Revolution and implications for innovative cluster policies." AI & Society 33(3): 433-445.
- Raaijmakers, S. (2022). Deep Learning for Natural Language Processing. Manning Publications Co.
- Rich, E., Knight, K., Nair, S. B. (2009). Artificial Intelligence. Third Edition. Tata McGraw Hill Education Private Limited.
- Sarkar, D. (2016). Text Analytics with Python: A Practical Real-World Approach to Gaining Actionable Insights from your Data. Apress Media, LLC.
- Stevens, E., Antiga, L., Viehmann, T. (2020). Deep Learning with PyTorch. Manning Publication Co.
- Subramanian, V.(2018). Deep Learning with PyTorch: A practical approach to building neural network models using PyTorch. Packt Publishing Ltd.
- Summerfield, M. (2007). Rapid GUI Programming with Python and Qt: The Definitive Guide to PyQt Programming. Pearson Education.
- Tkalac Verčić, A., Sinčić Ćorić, D., Pološki Vokić, N. (2010). Priručnik za metodologiju istraživačkog rada: Kako osmisliti, provesti i opisati znanstveno i stručno istraživanje. Zagreb: M.E.P. d.o.o.
- Van Rossum, G. (2003). An Introduction to Python. Release 2.2.2. Network Theory Limited.
- Yegnanarayana, B. (2009). Artificial Neural Networks. PHI Learning Pvt Ltd.
- Zelenika, R. (2000). Metodologija i tehnologija izrade znanstvenog i stručnog djela. Ekonomski fakultet Rijeka.

ČLANCI

- Afiouni, R. (2019). Organizational learning in the rise of machine learning. *International Conference on Information Systems, Munich, Germany*
- Alsheibani, S., Cheung, Y., Messom, C. (2018). Artificial intelligence adoption: AI-readiness at firm-level. *Artificial Intelligence*, 6, 26– 2018.
- Baesens, B., Verstraeten, G., Van den Poel, D., Egmont-Petersen, M., Van Kenhove, P., & Vanthienen, J. (2004). Bayesian network classifiers for identifying the slope of the customer lifecycle of long-life customers. *European Journal of Operational Research*, 156(2), 508–523.
- Balasundaram, S., Venkatagiri, S. (2020). A structured approach to implementing Robotic Process Automation in HR. *Journal of Physics: Conference Series*, 1427(1), 012008. IOP Publishing.
- Bauer, W., Vocke, C. (2019). Work in the age of artificial intelligence– challenges and potentials for the design of new forms of human machine interaction. *International Conference on Applied Human Factors and Ergonomics*.
- Borges, A. F., Laurindo, F. J., Spínola, M. M., Gonçalves, R. F., & Mattos, C. A. (2020). The strategic use of artificial intelligence in the digital era: Systematic literature review and future research directions. *International Journal of Information Management*, 102225.
- Buntak, K., Kovačić, M., Mutavdžija, M. (2020). Application of Artificial Intelligence in Business. *International Journal for Quality Research* 15(2) 403–416. DOI – 10.24874/IJQR15.02-03.
- Bytniewski, A., Matouk, K., Chojnacka-Komorowska, A., Hernes, M., Zawadzki, A., & Kozina, A. (2020). The functionalities of cognitive technology in management control system. *Asian Conference on Intelligent Information and Database Systems*.
- Castelli, M., Manzoni, L., & Popovic, A. (2016). An artificial intelligence system to predict quality of service in banking organizations. *Computational Intelligence and Neuroscience*. Article ID 9139380. Available at <https://doi.org/10.1155/2016/9139380>
- Coombs, C., Hislop, D., Taneva, S. K., & Barnard, S. (2020). The strategic impacts of Intelligent Automation for knowledge and service work: An interdisciplinary review. *The Journal of Strategic Information Systems*, 29(4), 101600.

- Dassisti, M., & Giovannini, A. (2012). Ontologies for interoperating sustainable manufacturing: new opportunities for the automotive sector. *International Journal of Automotive Technology and Management* 4, 12(3), 273–294.
- Davenport, T. H., Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- Dhruv, A.; Patel, R., Doshi, N. (2021). Python: The Most Advanced Programming Language for Computer Science Applications. In *Proceedings of the International Conference on Culture Heritage, Education, Sustainable Tourism, and Innovation Technologies - CESIT*; ISBN 978-989-758-501-2, SciTePress, 292-299. doi: 10.5220/0010307902920299
- Domingos, P. (2016) “The Supreme Algorithm. How Machine Learning Will Change Our World. Artificial Intelligence (AI): what, why and why.” by Dilya Zhanispayeva Medium
- Enholm, I. M., Papagiannidis, E., Mikalef, P., Krogstie, J. (2021). Artificial Intelligence and Business Value: a Literature Review. *Information Systems Frontiers* (2022) 24:1709–1734. <https://doi.org/10.1007/s10796-021-10186-w>
- Eriksson, T., Bigi, A., & Bonera, M. (2020). Think with me, or think for me? On the future role of artificial intelligence in marketing strategy formulation. *The TQM Journal*, 32(4), 795–814.
- Finch, G., Goehring, B., Marshall, A. (2017). The enticing promise of cognitive computing: high-value functional efficiencies and innovative enterprise capabilities. *Strategy & Leadership*, 45(6), 26–33.
- Frey, C.B., Osborne, M.A. (2017). The future of employment: how susceptible are jobs to computerisation? *Technol. Forecast. Soc. Change* 114, 254–280. <https://doi.org/10.1016/J.TECHFORE.2016.08.019>
- Garcia, H. C. E., Huerta, E. R. (2020). Machine Learning and Deep Learning Patentable Developments and Applications for Cost Reduction in Business and Industrial Organizations. *International Journal of Management and Information Technology* 5 (2) September 2020, 09-18
- González-Carvajal, S., Garrido-Merchán, E. C. (2021). Comparing BERT against traditional machine learning text classification. *Journal of Computational and Cognitive Engineering*. <https://doi.org/10.47852/bonviewJCCE3202838>

- Huang, M., Rust, R. T. (2018). Artificial Intelligence in Service. *Journal of Service Research* 2018, Vol. 21(2) 155-172.
- Ioannou, I., Serafeim, G. (2021). Corporate Sustainability: A Strategy? *Harvard Business School Working Paper* 19-065.
- J. E. Escrig, A. Simeone, E. Woolley, S. Rangappa, A. Rady, and N. J. Watson, "Ultrasonic measurements and machine learning for monitoring the removal of surface fouling during clean-in-place processes," *Food and Bioprocess Processing*, vol. 123, pp. 1-13, 2020, doi: <https://doi.org/10.1016/j.fbp.2020.05.003>.
- Jelonek, D., Mesjasz-Lech, A., Stępnia, C., Turek, T., Ziara, L. (2019). The artificial intelligence application in the management of contemporary organization: Theoretical assumptions, current practices and research review. *Future of Information and Communication Conference*.
- Keding, C. (2020). Understanding the interplay of artificial intelligence and strategic management: four decades of research in review. *Management Review Quarterly*. doi:10.1007/s11301-020-00181-x
- Ledeneva, Y., Sidorov, G. (2009). Recent Advances in Computational Linguistics. *Informatica* 34 (2010) 3–18.
- Lee, J., Suh, T., Toy, D., Baucus, M (2019). Emerging Technology and Business Model Innovation: The Case of Artificial Intelligence. *Journal of Open Innovation: Technology, Market, and Complexity*.
- Leech, G. (2013). Introducing corpus annotation. u Garside, R., Leech, G., McEnery, T. (Ur.) *Corpus Annotation. Linguistic Information from Computer Text Corpora*. (str. 1-19). Routledge. Taylor and Francis Group
- Loureiro, S. M. C., Guerreiro, J., & Tussyadiah, I. (2021). Artificial intelligence in business: State of the art and future research agenda. *Journal of Business Research*, 129, 911–926. doi:10.1016/j.jbusres.2020.11.001
- Makarius, E. E., Mukherjee, D., Fox, J. D., & Fox, A. K. (2020). Rising with the machines: A sociotechnical framework for bringing artificial intelligence into the organization. *Journal of Business Research*, 120, 262–273

- Mikalef, P., & Gupta, M. (2021). Artificial Intelligence Capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. *Information & Management*, Online. <https://doi.org/10.1016/j.im.2021.103434>
- Mishra, A. N., & Pani, A. K. (2020). Business value appropriation roadmap for artificial intelligence. *VINE Journal of Information and Knowledge Management Systems*, 51(3), 353–368
- Nishant, R., Kennedy, M., & Corbett, J. (2020). Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda. *International Journal of Information Management*, 53, 102104. doi:10.1016/j.ijinfomgt.2020.102104
- Nosova, S., Norkina, A., Makar, S. (2022) “Artificial Intelligence Technology as an Economic Accelerator of Business Process.” *Studies in Computational Intelligence* 1032 SCI: 355-366.
- Nosova, S., Norkina, A., Makar, S., Gerasimenko, T., Medvedeva, O. (2022). Artificial intelligence as a driver of business process transformation. *2022 Annual International Conference on Brain-Inspired Cognitive Architectures for Artificial Intelligence: The 13th Annual Meeting of the BICA Society*.
- Olsson, E., & Funk, P. (2009). Agent-based monitoring using case-based reasoning for experience reuse and improved quality. *Journal of Quality in Maintenance Engineering*, 15(2), 179–192.
- Popenici, S. A., & Kerr, S. (2017). Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology Enhanced Learning*, 12(1), 1-13.
- Purdy, M., Daugherty, P. (2016). Why Artificial Intelligence Is the Future of Growth. Remarks at AI Now: The Social and Economic Implications of Artificial Intelligence Technologies in the Near Term, pp. 1-72.
- Rahman, A., Ng, V. (2011). Coreference Resolution with World Knowledge. *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics*, pages 814–824, Portland, Oregon, June 19-24, 2011.
- Rao, P. J., Rao, K. N., Gokuruboyina, S. (2022). An Experimental Study with Fuzzy-Wuzzy (Partial Ratio) for Identifying the Similarity between English and French Languages for Plagiarism Detection. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, Vol. 13, No. 10, 2022.

- Rich, E. (1985). Artificial intelligence and the humanities. *Comput Hum* 19, 117–122. <https://doi.org/10.1007/BF02259633>
- Riikinen, M., Saarijärvi, H., Sarlin, P., & Lähteenmäki, I. (2018). Using artificial intelligence to create value in insurance. *International Journal of Bank Marketing*, 36(6), 1145–1168. <https://doi.org/10.1108/IJBM-01-2017-0015>.
- Semaan, P. (2012). Natural Language Generation: An Overview. *Journal of Computer Science & Research (JCSER) - ISSN 2227-328X*. Vol. 1, No. 3, Pages. 50-57, June 2012.
- Srinath, K. R. (2017). Python – The Fastest Growing Programming Language. *International Research Journal of Engineering and Technology (IRJET)*, Volume: 04 Issue: 12.
- Taylan, O., & Darrab, I. A. (2012). Fuzzy control charts for process quality improvement and product assessment in tip shear carpet industry. *Journal of Manufacturing Technology Management*, 23(3), 402–420. doi:10.1108/17410381211217434
- Thivaharan, S., Srivatsun, G., Sarathambekai, S. (2020). A Survey on Python Libraries Used for Social Media Content Scraping. *2020 International Conference on Smart Electronics and Communication (ICOSEC)*. doi:10.1109/icosec49089.2020.9
- Toniolo, K., Masiero, E., Massaro, M., & Bagnoli, C. (2020). Sustainable business models and artificial intelligence: Opportunities and challenges. In *Knowledge, People, and Digital Transformation* (pp 103–117). Springer. DOI:10.1007/978-3-030-40390-4_8
- Verma, S., Sharma, R., Deb, S., Maitra, D. (2020). Artificial intelligence in marketing: Systematic review and future research direction. *International Journal of Information Management Data Insights*. <https://doi.org/10.1016/j.ijime.2020.100002>
- Vlačić, B., Corbo, L., Costa e Silva, S., Dabić, M. (2021). The evolving role of artificial intelligence in marketing: A review and research agenda. *Journal of Business Research*, 128, 187-203. doi:10.1016/j.jbusres.2021.01.055
- Wamba-Taguimdje, S. L., Wamba, S. F., Kamdjoug, J. R. K., Wanko, C. E. T. (2020). Influence of artificial intelligence (AI) on firm performance: the business value of AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893–1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>.

- Weikum, G., Hoffart, J., Nakashole, N., Spaniol, M., Suchanek, F., Yosef, M. A. (2012). Big Data Methods for Computational Linguistics. *IEEE Computer Society Technical Committee on Data Engineering*.
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., Cistac, P., Rault, T., Louf, R., Funtowicz, M., Davison, J., Shleifer, S., von Platen, P., Ma, C., Jernite, Y., Plu, J., Xu, C., Le Scao, T., Gugger, S., Drame, M., Lhoest, Q., Rush, A. M. (2020). Transformers: State-of-the-Art Natural Language Processing. *Hugging face*.
- Wu, D. Z., Ren, A. Q., Zhang, W. H., Fan, F. F., Liu, P., Fu, X. W., & Terpenney, J. (2012). Cybersecurity for digital manufacturing. *Journal of Manufacturing Systems*, 48, 3–12.
- Z. Ge, Z. Song, S. X. Ding, and B. Huang, "Data mining and analytics in the process industry: The role of machine learning," *IEEE Access*, vol. 5, pp. 2059020616, 2017.
- Zelenika, R., Zelenika, S. (2007): Klasifikacija znanosti u fokusu metodologije i tehnologije znanstvenog istraživanja, *Pomorski zbornik*, 44(1), str. 11-40.
- Zhao, J., Wu, M., Zhou, L., Wang, X., Jia, J. (2022). Cognitive psychology-based artificial intelligence review. *Frontiers In Neuroscience*. 16:1024316. doi: 10.3389/fnins.2022.1024316
- Zou, J., Han, Y., So, S.-S. (2008). Overview of Artificial Neural Networks. *Artificial Neural Networks*, 14–22. doi:10.1007/978-1-60327-101-1_2
- Žugalj, M. (1979): Metode analize i sinteze. *Journal of Information and Organizational Sciences*, 2-3, str. 113-139.

INTERNET UZVORI

- Autor nepoznat. (8. lipnja, 2024). Case Study: Zara's Comprehensive Approach to AI and Supply Chain Management. AI Expert Network, <https://aiexpert.network/case-study-zaras-comprehensive-approach-to-ai-and-supply-chain-management/>
- Eurostat Statistics Explained. (2024, svibanj). Use of artificial intelligence in enterprises. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Use_of_artificial_intelligence_in_enterprises

Eurostat. (2022, 9. lipnja). Smart technologies in EU enterprises: AI and IoT. <https://ec.europa.eu/eurostat/en/web/products-eurostat-news/-/ddn-20220609-1>

PwC (2017) Global Artificial Intelligence Study: Exploiting the AI Revolution. <https://www.pwc.com/gx/en/issues/analytics/assets/pwc-ai-analysis-sizing-the-prize-report.pdf>

SAŽETAK

Umjetna inteligencija danas dotiče svaki dio života, a organizacija se očekuje implementacija kako bi zadržale konkurentsku prednost i opstale na dinamičnom globalnom tržištu. Ovaj rad istražuje implementaciju modela obrade prirodnog jezika i umjetne inteligencije u poslovnim procesima, ističući njihove prednosti u automatizaciji, analizi i optimizaciji procesa. Unatoč izazovima kao što su kompleksnost implementacije, troškovi, sigurnost i privatnost podataka, rezultati eksperimentalnog dijela istraživanja pokazuju značajan potencijal ovih tehnologija za povećanje učinkovitosti i točnosti u obradi nestrukturiranih tekstualnih podataka. Rad također naglašava potrebu za daljnjim istraživanjem i prilagodbom umjetne inteligencije i modela obrade prirodnih jezika specifičnim potrebama organizacije.

Ključne riječi: obrada prirodnog jezika, umjetna inteligencija, Python, nestrukturirani tekstualni podatci

SUMMARY

Today, artificial intelligence impacts every part of life, and organizations are expected to implement it to maintain a competitive advantage and survive in the dynamic global market. This paper explores the implementation of natural language processing models and artificial intelligence in business processes, highlighting their advantages in automation, analysis, and process optimization. Despite challenges such as implementation complexity, costs, security, and data privacy, the results of the experimental part of the research demonstrate significant potential of these technologies for increasing efficiency and accuracy in processing unstructured textual data. The paper also emphasizes the need for further research and adaptation of artificial intelligence and natural language processing models to the specific needs of organizations.

Keywords: natural language processing, artificial intelligence, Python, unstructured textual data