Sustav potpore korisnicima temeljen na bazi znanja i konverzacijskoj komponenti

Matešić, Maja

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:755677

Rights / Prava: Attribution 3.0 Unported/Imenovanje 3.0

Download date / Datum preuzimanja: **2025-03-23**

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Maja Matešić

Sustav potpore korisnicima temeljen na bazi znanja i konverzacijskoj komponenti

ZAVRŠNI RAD

Varaždin, 2024.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Maja Matešić

Matični broj: 35918/07–R

Studij: Informacijski i poslovni sustavi

Sustav potpore korisnicima temeljen na bazi znanja i konverzacijskoj komponenti

ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Vjeran Strahonja

Varaždin, lipanj 2024.

Maja Matešić

Izjava o izvornosti

Izjavljujem da je moj završni/diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autorica potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

ZAHVALE

Prvenstveno se zahvaljujem mentoru prof. dr. sc. Vjeranu Strahonja, koji je već od prvog predavanja imao snažan utjecaj na moje obrazovanje. Njegova podrška, znanje i iskustvo vodili su me kroz proces učenja i oblikovali moje profesionalne interese. Također, želim izraziti zahvalnost svim profesorima koji su svojim znanjem i nesebičnim dijeljenjem iskustava obogatili moj put obrazovanja.

Zahvaljujem se stručnjacima iz CRM odjela Privredne banke Zagreb, a posebno mentorici Marti Hajdina, na nesebičnom dijeljenju znanja i savjeta o specifičnostima bankarskih usluga. Razgovori s njima bili su od ključne važnosti za razumijevanje internih procesa i izazova u pružanju korisničke podrške. Također, zahvaljujem svim korisnicima čije su povratne informacije doprinijele finom podešavanju chatbota i poboljšanju njegove funkcionalnosti.

Na kraju, posebna zahvala ide mojoj obitelji i prijateljima. Vaša ljubav, podrška i vjera u mene bili su moj oslonac kroz sve izazove i uspjehe. Bez vas, ovaj uspjeh ne bi bio moguć.

Sažetak

Ovaj završni rad bavi se razvojem marketinškog chatbota za bankarsku industriju sa ciljem unaprjeđenja korisničkog iskustva i promocije bankarskih usluga. Fokus rada je na implementaciji tehnologije umjetne inteligencije, konkretno generativne umjetne inteligencije (GenAI), te integraciji s bazom znanja banke kako bi chatbot mogao pružiti personalizirane preporuke i odgovore korisnicima. Istraživanje koristi akcijsko istraživanje kao metodološki okvir, a podaci su prikupljeni putem neformalnih intervjua, odnosno informiranja s djelatnicima Privredne banke Zagreb (PBZ). Glavne funkcionalnosti chatbota uključuju mogućnost obrade korisničkih upita, pružanje informacija o bankarskim proizvodima i uslugama, te automatsko prepoznavanje prilika za promociju. Evaluacija prototipa pokazuje da chatbot značajno smanjuje troškove korisničke podrške te poboljšava učinkovitost komunikacije između banke i korisnika. Rad također raspravlja o etičkim aspektima primjene AI tehnologija u bankarstvu, uključujući privatnost podataka i potencijalne izazove.

Ključne riječi: chatbot; generativna umjetna inteligencija; CRM; korisnička podrška; bankarske usluge; PBZ; automatizacija**.**

Sadržaj

Sadržaj....iv
1. Uvod....1
2. Metode i tehnike rada....3
3. Sustav potpore korisnicima....4
3.1. Upravljanje odnosima s klijentima....4
3.2. Pregled primjene UI u razvoju sustava za podršku korisnicima....5
3.2.1. Chatbot kao sustav potpore korisnicima....6
3.2.2. Konverzacijski sustavi i odgovaranje na često postavljena pitanja....7
3.2.3. Upravljanje bazom znanja....8
4. CRM u banci....10
5. Izgradnja chatbota za bankarstvo....11
5.1. Trenutno stanje....11
5.2. Razvoj korisničkog sučelja....11
5.2.1. Alat Promptly....11
5.2.2. Mogućnosti kreiranja AI agenata putem Promptly platforme....11
5.2.3. Koncepti i funkcionalnosti platforme....13
5.2.4. Identifikacija funkcionalnosti....14
5.2.5. Sučelje i arhitektura sustava....15
5.2.6. Prototip....32
5.3. Unaprijeđeni chatbot....35
6. Zaključak....37
7. Popis literature....38
8. Popis slika....40

1. Uvod

Živimo u brzom svijetu u kojem pojedinci koriste mobilne tehnologije i dodatke za rješavanje problema, održavanje sastanaka ili komuniciraju sa svojim financijama. Vodeće tehnološke tvrtke – Google, Microsoft, Apple, Facebook – postavile su ljestvicu visoko, stoga sada korisnici očekuju bezbroj usluga i proizvoda koji će biti dostupni dvadeset i četiri sata u danu, a pritom osiguravaju revolucionarna korisnička iskustva i neposrednu višekanalnu podršku. Korisnici ne razmišljaju o broju klijenata banke, već očekuju individualni i kvalitetan pristup neovisno, što je izazovno za pružatelje financijskih usluga. Zadovoljiti te zahtjevne standarde i zadržati svoje vodeće pozicije nemoguće je bez tehnologije. Tu se pojavljuje kognitivna tehnologija i automatizacija.

Banke i druge financijske institucije koje blisko surađuju s klijentima i uvelike se oslanjaju na odnose s klijentima, uvijek su koristile tehnologiju kao alat, u cilju olakšavanja procesa komuniakcije s golemom količinom klijenata koje opslužuju (ili business-to-customer poslovanje). Korištenje tehnologije smanjuje količinu vremena za koju se što manje resursa i što manje radne snage koristi za velik broj korisnika. Prvo je to bilo internet bankarstvo u kasnim devedesetima, zatim mobilno bankarstvo kada je revolucija pametnih telefona zavladala svijetom. Sada, s dolaskom ponovnog uspona umjetne inteligencije konverzacijsko bankarstvo je u proboju. Zvuči kompliciranije nego što jest, konverzacijsko bankarstvo nije ništa drugo nego komunikacija između klijenta i banke putem teksta, glasa ili vizualno sučelje. Bitno je pribrojiti što više moguće personalizacije u odnosu s klijentima.

Korisnička podrška ima ključnu ulogu u sposobnosti organizacije da ostvaruje prihod. Često je jedan od najresursno zahtjevnijih odjela unutar tvrtke, što rezultira troškovima u milijardama dolara godišnje, sve u cilju poboljšanja percepcije korisnika o tvrtki. Timovi za podršku ulažu mnogo vremena odgovarajući na upite putem telefona ili aplikacija za razmjenu poruka, kako bi osigurali zadovoljstvo korisnika. Tradicionalni modeli korisničke podrške suočavaju se s dva glavna izazova: Prvi je ponavljanje istih pitanja od strane različitih korisnika, na koja bi strojevi mogli odgovoriti učinkovitije i uz manje troškove. Drugi je izazov pružanje podrške 24 sata dnevno, 7 dana u tjednu, što je posebno teško za tvrtke koje nemaju globalno poslovanje.

U posljednjih par godina na pitanje automatizacije komunikacije odgovor je chatbot. Trenutno virtualni pomoćnici u kombinaciji s tehnologijama umjetne inteligencije, *Natural Language Processing* i strojnog učenja mogu imitirati ljudske razgovore kako bi pomogli financijskim tvrtkama da uklone komunikacijske praznine između klijenata i poslovanja, kao i kako bi uspostavili dodatne komunikacijske kanale. Automatiziranje odnosa s klijentima znači

i značajnu uštedu. Klijentima odgovara da dok koriste sučelje imaju dojam da razgovaraju s agentom u poslovnici.

Implementacija razgovornog agenta složen je zadatak budući da uključuje razumijevanje jezika i upravljanje dijalogom. Najjednostavniji način implementacije konverzacijskog agenta jesu chatbotovi, [1] dijaloški sustavi bazirani na podudaranju uzoraka između korisničkih upita i skupa pravila definiranih u bazi znanja.

Chatbot služi kao imitacija osobe čija ja dužnost uputiti klijenta ili korisnika kroz usluge ili konkretne korake određene usluge. Na temelju unosa, kretat će se bazom znanja i biti vodič korisniku. Pristupačno i funkcionalno sučelje između inteligentnog sustava i korisnika je od posebnog interesa.

2. Metode i tehnike rada

Prikupljanje podataka za ovaj studij uključuje intervjue i rasprave s djelatnicima CRM odjela Privredne banke Zagreb, gdje sam tijekom treće godine studija odrađivala praksu. Razgovori su vođeni s nekoliko zaposlenika različitih profila unutar odjela, što je omogućilo detaljan uvid u postojeće procese i izazove s kojima se susreću. Mentor tijekom prakse bila mi je stručnjakinja iz CRM odjela, što je dodatno obogatilo kvalitetu prikupljenih informacija.

Studij započinje analizom trenutnog stanja kojom identificiram problem. Nakon analize trenutnog modela, implementacija korisničkog sučelja s funkcionalnostima za pregledavanje prijašnjih upita i odgovora može značajno poboljšati korisničko iskustvo s chatbotom i pružiti dodatnu vrijednost korisnicima.

Studij započinje analizom trenutnog stanja kojom identificiram problem. Nakon analize trenutnog modela, zaključeno je da implementacija korisničkog sučelja s funkcionalnostima za pregledavanje prijašnjih upita i odgovora može značajno poboljšati korisničko iskustvo s chatbotom i pružiti dodatnu vrijednost korisnicima.

Dokument koji služi kao baza znanja kreiran je analizom web-stranice Privredne banke Zagreb.

Promptly alat [23] korišten je za kreiranje chatbota s vlastitom bazom znanja, a Figma za dizajn korisničkog sučelja. Promptly je posebno zanimljiv jer smo ga koristili i tijekom laboratorijskih vježbi na kolegiju Primjena umjetne inteligencije u poslovanju, što nam je omogućilo dubinsko razumijevanje njegovih funkcionalnosti. Na kraju, provest će se evaluacija novog sustava podrške, uspoređujući njegovu učinkovitost s postojećim modelom. Promptly je omogućio jednostavnu integraciju baze znanja i razvoj funkcionalnog chatbota.

Poveznica na chatbot aplikaciju je: https://trypromptly.com/app/dbfdeeda-9bca-4141-8dc6-db74e2ff28c0.

3. Sustav potpore korisnicima

U glavnom dijelu rada razrađuje se tema kroz detaljna istraživanja, analizu rezultata, te prikazivanje ključnih aspekata problema i njihovih rješenja. Kroz analizu i interpretaciju prikupljenih podataka, isto tako detaljne opise korištenja alata, rad će ukazati na važnost i utjecaj razvijenog rješenja u kontekstu šireg područja istraživanja.

3.1. Upravljanje odnosima s klijentima

Upravljanje odnosima s klijentima ili bolje poznatije kao CRM (*Customer Relationship Management*) ujedinjuje potencijal strategija marketinga odnosa i informacijske tehnologije kreirajući protitabilne, dugoročne odnose s kupcima i drugim ključnim dionicima. Komunikacijski modeli evoluirali su da uzmu u obzir više-prema-više interakcije, posebice nakon pojave društvenih medija. [2]

Sposobnosti marketinškog sustava za potporu korisnicima kao što je marketinški chatbot jesu prikupljanje podataka o kupcima i potencijalnim kupcima, zatim procesuiranje tih podataka i na temelju analize, izvršavanje CRM strategija.

Reinartz i suradnici [7] prepoznaju tri CRM procesa koja izravno utječu na rezultate poslovanja: iniciranje odnosa, održavanje odnosa i prekid odnosa. U njihovom istraživanju, najveći utjecaj na performanse proizlazi iz procesa održavanja i iniciranja odnosa. U obje faze, povezane sposobnosti uključuju: (1) korištenje društvenih mreža za marketinške i komunikacijske aktivnosti [6], (2) sposobnosti angažmana korisnika koje olakšavaju interakcije između tvrtke i korisnika, kao i između korisnika međusobno [8], te (3) mogućnost prikupljanja različitih vrsta podataka o korisnicima s društvenih mreža [5]. Međutim, prekidanje odnosa s korisnicima, čak i kada nisu profitabilni, identificirano je kao ograničenje menadžera. Pitanje koje se postavlja u ovom kontekstu je bi li ne-ljudski donositelji odluka te prekide izvršavali sustavnije. Na srednjoj razini, Payne i Frow [5] tvrde da je CRM prikazan kroz funkcionalni, procesno orijentirani pristup. Njihov rad identificira pet međufunkcionalnih procesa koji omogućuju strateško korištenje CRM alata: proces razvoja strategije, proces stvaranja vrijednosti, proces višekanalne integracije, proces upravljanja informacijama i proces procjene uspješnosti.

3.2. Pregled primjene UI u razvoju sustava za podršku korisnicima

Chatbot-ovi se mogu pronaći u raznim komunikacijskim kanalima, uključujući chat-ove na web-mjestima, WhatsApp, Facebook, Messenger i druge, radi upoznavanja i praktičnosti pristupa i korištenja. [9]

Prema Belli Church, strateškom stručnjaku za IBM watsonx, na IBM-ovu blogu postoji sljedeća podjela chatbotova [10]:

- Chatbotovi temeljeni na izbornicima (*Menu-based chatbots*): Korisnici biraju odgovore iz unaprijed definiranih opcija putem izbornika. Ovi sustavi su jednostavni, ali ograničeni kada korisnici imaju složenije zahtjeve.
- Chatbotovi temeljeni na pravilima (*Rules-based chatbots*): Koriste logiku "ako/onda" za odgovaranje na upite. Iako mogu automatski odgovarati na predefinirana pitanja, ne mogu se nositi s neočekivanim upitima.
- Chatbotovi s UI-om (*AI-powered chatbots*): Koriste NLP i strojno učenje kako bi razumjeli kontekst i učili iz interakcija, pružajući inteligentnije odgovore s vremenom.
- Glasovni chatbotovi (*Voice chatbots*): Korisnici komuniciraju glasom umjesto putem tipkovnice, koristeći tehnologije prepoznavanja i sinteze govora.
- Generativni chatbotovi (*Generative AI chatbots*): Koriste napredne jezične modele (*LLM*) za stvaranje novog sadržaja, poput teksta, slika ili zvuka, temeljenog na korisničkim upitima.

Odabrana vrsta za ovaj primjer je generativni chatbot.

Autorica članka, Church [10] također objašnjava kako odabrati vrstu prikladnu poslovanju, odgovara na pitanje „Koji je pravi tip chatbota za vaše poslovanje?“
Prilikom odabira chatbota, važno je staviti korisnika u središte odluke. Bitno je razmotriti koje su njihove potrebe i preferencije u korisničkom iskustvu – žele li jednostavne opcije putem izbornika ili mogućnost vođenja otvorenog dijaloga? Također, važno je uzeti u obzir veličinu poduzeća i namjenu chatbota. Manja poduzeća s jednostavnim potrebama mogu se osloniti na chatbotove temeljene na pravilima, dok veća poduzeća s puno podataka mogu koristiti AI chatbotove za pružanje detaljnih, personaliziranih odgovora. Generativni AI chatbotovi donose dodatnu kreativnost u interakciji.

Ove različite vrste chatbotova omogućuju bankama da poboljšaju interakciju s korisnicima pružanjem bržih, točnijih i personaliziranih odgovora.

Jedan od ključnih elemenata uspješnog CRM-a je sposobnost pružanja personaliziranih iskustava koja odgovaraju potrebama i preferencijama korisnika. Tehnologija umjetne inteligencije nudi veliki potencijal u automatizaciji interakcija, dobivanju uvida iz velikih korisničkih podataka te poboljšanju učinkovitosti i efikasnosti u komunikaciji s korisnicima[12].

3.2.1. Chatbot kao sustav potpore korisnicima

Sljedeći odlomak pokriva definiranje chatbot-a, funkcionalnosti i prednosti za korisnike i tehnološku osnovu.

Pružanje izvrsne korisničke usluge jedan je od načina na koji kompanija može postići konkurentsku prednost. Korisnici cijene neposrednost, pristupačnost i dosljednost usluge. Povijesno gledano, brendovi su nastojali zaposliti osoblje i pružiti im obuku, znanje i empatiju potrebnu za pružanje visokokvalitetne korisničke usluge. Međutim, brendovi se sve više okreću novim tehnologijama kako bi angažirali kupce i pružili korisničku uslugu [11]. Tehnologija o kojoj je najčešće riječ je generativna umjetna inteligencija, eng. *GenAI*. Na fronti su također chatbot-ovi kao zamjena za razgovor s agentima. Naime, razgovorni agent i chatbot nisu ekvivalenti.

Virtualni agent vrlo je moćan alat koji može komunicirati s klijentima i potencijalnim potencijalnim kupcima.[13]

Chatbot je automatizirani razgovorni agent koji nudi unaprijed definirane odgovore prema upitu kupca. Skenira sve dostupne informacije u bazi znanja, koja služi poput knjižnice. Chatbot će na temelju poruka klijenta ili odabrane opcije, brzo iz baze podataka izvući najbolji odgovor. U usporedbi sa ljudskim agentom korisničke službe, chatbot je dostupan bez prestanka i može odgovoriti na zahtjeve korisnika pitanja odmah. Ovo je vrsta umjetne inteligencije koja će kada se ispravno upotrijebi utjecati na integritet i ugled tvrtke. Primjeri upotrebe razgovornih agenata uz tehniku generativne umjetne inteligencije su IBM-ov *Watson Assistant*, Salesforce-ov *Service Cloud Einstein* i Google-ov *Dialogflow*.[14]

Glavna razlika između chatbota i razgovornog agenta leži u njihovoj složenosti i mogućnostima. Chatbot je obično programiran za odgovaranje na jednostavne, unaprijed definirane upite putem izbornika ili pravila. S druge strane, razgovorni agent koristi naprednu umjetnu inteligenciju i obradu prirodnog jezika kako bi procesuirao složenije upite, učio iz interakcija i vodio prirodnije razgovore. Razgovorni agenti mogu pružiti personalizirane odgovore, dok chatbot-ovi funkcioniraju unutar ograničenog skupa opcija. [16]

Sve veći broj brendova koristi chatbotove za zadatke korisničke službe kao što su rješavanje pritužbi, prepoznavanje artikala za kupnju i pružanje podrške nakon prodaje. [15]

Iz perspektive učinkovitosti, procjene su 2019. godine bile da će chatbotovi s umjetnom inteligencijuom napraviti uštedu od 7,3 milijarde dolara samo u bankarskom i financijskom sektoru diljem svijeta do 2023. godine, što je ekvivalentno 862 milijuna radnih sati. [18]

Konverzacijski agenti uparuju korisnički unos sa sadržajem unaprijed definirane baze znanja koristeći algoritam. Odgovori su kreirani od strane developera koji definiraju odgovore na najčešće postavljena pitanja korisnika i tako kreiraju šablonu. Dakle, što je baza znanja opširnija, utoliko je chatbot sposobniji odgovoriti. S druge strane, oni koji su temeljeni na sustavu generiranja koriste strojno ili duboko učenje kako bi generirali odgovore. Početno, stvorimo skup za treniranje koji sadrži ljuski razgovor kako bi se izgradilo razumijevanje jecičnih i razgovornih obrazaca, fraza, odnosa, značenja, konteksta i prikladnih odgovora. [17]

Oko 80% upita od strane korisnika se mogu riješiti chatbotovima jer su pitanja rekurentna – nema potrebe za predstavnicima korisničke službe. [19] Za kompanije, neovisno o veličini, ovo je odlična solucija, jer time dobiju više vremena za kompleksnije probleme. Ideja je da se, osim što se „rješavaju problemi“, odnosno upiti korisnika i potencijalnih korisnika, tim putem promoviraju raznovrsne usluge gdje se ugleda prilika.

Chatbot je osmišljen da odgovara na često postavljana pitanja korisnika, pruža informacije o različitim uslugama banke, poput računa, kredita i osiguranja, te nudi personalizirane preporuke na temelju korisničkih potreba. Integriran je s bazom znanja, što mu omogućuje da brzo preuzme relevantne podatke i pruži korisnicima točne i korisne informacije. Obilježava ga generativna umjetna inteligencija.

Zamisao je da chatbot umjesto zaposlenika na šalteru osigura najbitniji element kod ponašanja kupca, a to je donošenje odluke o kupnji proizvoda i usluga u korist banke. Prema knjizi autora Dobrinić i Gregurec [20] neke od odluka se donose rutinski, npr. odabir restorana, dok s druge strane neke odluke iziskuju velik napor i uključenost kupaca u cijeli proces odlučivanja (npr. odabir kredita).

Ipak, postoje izazovi povezani s uslugama za korisnike omogućenim umjetnom inteligencijom, riskira se sigurnost podataka koja izaziva negativne osjećaje kod korisnika. Preporučljivo je analizirati u kojem opsegu se razgovorni agent implementira i za koji aspekt poslovanja.

3.2.2. Konverzacijski sustavi i odgovaranje na često postavljena pitanja

Jedna od ključnih prednosti konverzacijskih sustava je njihova sposobnost odgovaranja na često postavljena pitanja (FAQ). Banke, primjerice, koriste chatbotove za odgovaranje na standardna pitanja poput otvaranja računa, stanja na računu, dostupnosti kredita ili upita o sigurnosnim protokolima. Kao što je spomenuto, time se osigurava da se agenti u banci mogu fokusirati na kompleksnije probleme.

Prikupljanje često postavljenih pitanja (*FAQ*) ključno je za uspjeh konverzacijskih sustava. Jedan od najučinkovitijih načina jest analiza postojećih korisničkih interakcija, uključujući e-mailove, chatove i pozive. Uz to, ankete i povratne informacije od korisnika mogu otkriti najčešće upite te osvijetliti područja koja trebaju poboljšanje . Analitika web-stranice može pomoći u praćenju korisničkih pretraga i interakcija, identificirajući tako najtraženije informacije .

Automatizacija odgovora na često postavljena pitanja također doprinosi poboljšanju korisničkog iskustva, jer chatbotovi mogu ponuditi precizne odgovore uz minimalne pogreške. Implementacija takvih sustava u bankarskim institucijama omogućuje optimizaciju radnih procesa i smanjenje troškova povezanim s podrškom korisnicima, dok u isto vrijeme povećava zadovoljstvo korisnika.

Konverzacijski sustavi koriste se u bankama i drugim financijskim institucijama za rješavanje upita korisnika, čime se smanjuje pritisak na korisničku službu. Na primjer, *Bank of America* koristi virtualnog asistenta *Erica*, koji pomaže korisnicima u jednostavnim financijskim transakcijama i informacijama o stanju računa. [21]

Slično tome, banka *Wells Fargo* koristi chatbotove za odgovaranje na često postavljena pitanja korisnika, uključujući otvaranje računa i postavljanje sigurnosnih postavki.

3.2.3. Upravljanje bazom znanja

Upravljanje bazom podataka odnosi se na organizaciju, skladištenje i pristup podacima na način koji omogućuje učinkovito korištenje i brzu dostupnost informacija. U ovom kontekstu, od ključne važnosti su alati koji podržavaju integraciju podataka, zaštitu privatnosti korisnika, te održavanje točnosti i dosljednosti podataka.

Upravljanje bazom znanja ključno je za učinkovit rad konverzacijskih sustava, jer omogućuje sustavima pristup informacijama potrebnim za davanje točnih i korisnih odgovora. Baza znanja može sadržavati raznolike podatke poput pravila poslovanja, odgovora na često

postavljena pitanja, tehničke informacije te specifične uvjete i odredbe za proizvode i usluge banke. Da bi chatbotovi mogli ispravno funkcionirati, baza znanja mora biti ažurirana, točna i pravilno strukturirana.

U kontekstu bankarstva, upravljanje bazom znanja obuhvaća organizaciju svih relevantnih podataka koji se mogu automatski dostaviti korisnicima putem chatbota. Ovaj proces uključuje redovito ažuriranje podataka kako bi se osiguralo da chatbot pruža aktualne informacije o financijskim proizvodima, promjenama u zakonodavstvu ili internim pravilima banke. Efikasno upravljanje bazom znanja također uključuje kategorizaciju podataka, definiranje relevantnih ključnih riječi i optimizaciju sadržaja za brzi pristup. Chatbotovi koji imaju pristup dobro organiziranoj i sveobuhvatnoj bazi znanja mogu poboljšati kvalitetu korisničke podrške i omogućiti preciznije i kontekstualno relevantne odgovore.

Dokumenti koje je moguće učitati kao izvor podataka za chatbot u alatu Promtly su primjerice PDF, CSV, URL. Odabrala sam Word dokument kao bazu znanja jer omogućuje jednostavno strukturiranje i unos velike količine podataka, formatiran je dokument i time je chatbot-u olakšano da prepozna ključne informacije kao što su naslovi, podnaslovi te tekstualni blokovi, Unosom ovog dokumenta u Promptly alat, podaci se mogu segmentirati u manje dijelove i tako povezati s odgovarajućim upitima korisnika.

Dokument pod nazivom "PBZ Usluge" sadrži detaljan pregled različitih financijskih proizvoda i usluga koje nudi Privredna banka Zagreb (PBZ). Opisane su svakodnevne financijske usluge poput tekućih računa, kreditnih kartica, digitalnog bankarstva, te kredita za stambene potrebe i obrazovanje. Također, pokrivene su opcije štednje i investicija, kao i osiguravateljske usluge poput životnog, putnog i imovinskog osiguranja. Error: Reference source not found

Ovaj dokument sam sastavila koristeći informacije sa službene web stranice Privredne banke Zagreb, koja je javno dostupna svima. Budući da je dokument u Word formatu prikladan za strukturiranje i organizaciju podataka, odlučila sam koristiti ovu vrstu baze znanja. Na taj način je omogućeno jednostavno ažuriranje i pristup informacijama potrebnim za treniranje i funkcioniranje chatbota. Integracija znanja iz ovog izvora obavljena je kroz strukturiranje sadržaja u kategorije i optimizaciju podataka za brzi pristup.

Za integraciju znanja iz više izvora alat Promptly bi se pokazao kao prikladan, jer omogućuje unos i organizaciju podataka, olakšavajući strukturiranje baze znanja chatbota. Postupak treniranja započinje izradom baze znanja na temelju informacija s web stranice banke, nakon čega se dokument uvozi u Promptly, gdje se podaci kategoriziraju i optimiziraju. Chatbot se potom trenira na ovim podacima, prepoznajući obrasce u korisničkim upitima. Nakon treniranja, chatbot se testira i evaluira kako bi se procijenila njegova

učinkovitost, a povratne informacije koriste se za daljnja poboljšanja, čime se osigurava kontinuirano unapređenje performansi.

Dokument „PBZ Usluge“ služi kao baza znanja u alatu Promptly. Chatbot koristi informacije iz ovog dokumenta za pružanje točnih i ažuriranih podataka korisnicima o PBZ-ovim uslugama. Pomoću analize sadržaja iz dokumenta, chatbot je sposoban prepoznati korisničke upite i automatski davati relevantne odgovore vezane uz određene financijske proizvode, poput informacija o vrstama računa, opcijama štednje, kreditima i uslugama digitalnog bankarstva.

4. CRM u banci

Općenito, upravljanje odnosima s kupcima (CRM) predstavlja ključnu poslovnu strategiju usmjerenu na izgradnju i održavanje profitabilnih odnosa s kupcima kroz dizajniranje i pružanje visoke razine vrijednosti. Ova strategija se oslanja na visokokvalitetne podatke o kupcima koji su podržani informacijskom tehnologijom. [4]

CRM je ključna poslovna strategija koja obuhvaća ne samo informacijsku tehnologiju, već sve aspekte poslovanja povezane s kupcima. Bavi se akvizicijom novih kupaca u fazi stvaranja, a u fazi održavanja osigurava se da su postojeći kupci stalni kupci, te se u fazi profitabilnosti osigurava da su vrijedni kupci oni koji su lojalni. Neki kupci mogu biti previše skupi za akviziciju i održavanje, što omogućuje menadžerima primjenu strategije otpuštanja neprofitabilnih kupaca. CRM dizajnira i isporučuje visoku kvalitetu vrijednosti, poduzeća kreiraju vrijednosti i predstavljaju ih kupcima putem raznih kanala komunikacije i distribucije. Korištenjem usluga, kupci stječu određena iskustva, a cilj poduzeća je osigurati visoku kvalitetu tih iskustava.[4]

Danas mnoge tvrtke, poput banaka, prepoznaju važnost upravljanja odnosima s kupcima za stjecanje novih, zadržavanje postojećih kupaca i maksimizaciju njihove vrijednosti, pri čemu je nužna bliska suradnja IT i marketinških odjela za dugoročno zadržavanje odabranih kupaca. Dakle, od velike je važnosti aplicirati isto i u bankarsku tvrtku.

Suresh [22] je predložio nekoliko koraka koje banke mogu poduzeti kako bi učinkovito provodile CRM. Prvo, banke bi trebale brzo odgovarati na e-mail upite, automatski potvrđujući primitak poruke i pružajući rok za odgovor. Drugo, važno je razviti pravu strategiju kontakta, kako bi banke nudile odgovarajuće pogodnosti različitim kupcima bez nepotrebnog iritiranja. Treće, online chat može poslužiti kao alternativa telefonskoj podršci, omogućujući agentima da istovremeno rješavaju više problema. Četvrto, poboljšanje dizajna web stranice i sustava samoposluživanja može smanjiti troškove skupih kanala podrške poput telefona i e-

maila. Na kraju, važno je analizirati opseg CRM projekta, integrirati različite odjele i promijeniti fokus s tretiranja klijenata kao računa na izgradnju dugoročnih odnosa.

Primarna uloga suvremenih banaka je plasiranje proizvoda prema tržišno-poduzetničkim načelima. Sve veća informatizacija radnih mjesta također pridonosi razvoju modernog bankarstva. Za razliku od tradicionalnog, moderno bankarstvo značajno je smanjilo troškove poslovanja i pružanja usluga, što je dovelo do porasta broja korisnika. [22]

5. Izgradnja chatbota za bankarstvo

5.1. Trenutno stanje

Trenutno, PBZ ima chatbot koji klijentima odgovara na postavljena pitanja, konkretno i pouzdano. Inspirirana tim prezicno kreiranim primjerom, osmislit ću i kreirati marketinški chatbot za promociju usluga i proizvoda banke kao izvrstan način za povećanje angažmana korisnika i promociju velike palete usluga. Klijentu će se omogućiti nepostojanost reda čekanja i prostornog ograničenja, brzina kojom dobije informaciju i kontinuirani pristup informacijama. Dakle, 24 sata dnevno, 365 dana u godini klijent ili potencijalni klijent ima konverzacijsko sučelje na raspolaganju, ne oviseći o neradnim danima niti velikim redovima čekanja. Za ovakvu vrstu chatbota nije potrebno registrirati račun.

PBZ-ov virtualni asistent može se koristiti na računalima, pametnim telefonima ili tabletima te omogućuje pristup informacijama vezanim uz bankarske usluge, digitalno bankarstvo, kredite i pronalaženje poslovnica ili bankomata. Korisnici mogu birati teme iz izbornika ili postavljati pitanja slobodnim unosom. Virtualni asistent je u stalnom procesu učenja i prilagođavanja, a za kompleksnije upite korisnici se mogu preusmjeriti na e-agenta unutar radnog vremena. Asistent savjetuje korisnicima da ne dijele osobne ili financijske podatke radi sigurnosti.

5.2. Razvoj korisničkog sučelja

5.2.1. Alat Promptly

Promptly je platforma koja omogućuje kreiranje generativnih AI agenata, radnih tokova i chatbotova bez potrebe za programiranjem, te njihovo povezivanje s vašim podacima i poslovnim procesima. Ovaj okvir služi za izgradnju novih AI iskustava ili integraciju umjetne inteligencije u postojeće proizvode. Platforma Promptly dizajnirana je da bude modularna i proširiva, olakšavajući upravljanje podacima koji se mogu povezati s

aplikacijama temeljenim na velikim jezičnim modelima (LLM) kako bi se stvorili generativni AI agenti svjesni konteksta.

5.2.2. Mogućnosti kreiranja AI agenata putem Promptly platforme

Promptly platforma omogućuje kreiranje generativnih AI agenata bez potrebe za kodiranjem. Agenti poput AI SDR-ova, istraživačkih analitičara ili RPA automatizacija mogu se povezati s internim ili vanjskim alatima, omogućujući im pretraživanje interneta i izvršavanje složenih zadataka. Platforma omogućuje povezivanje više velikih jezičnih modela (LLM-ova), čime korisnici mogu graditi složene AI aplikacije. Podaci iz različitih izvora, poput CSV-a, PDF-a ili Google Diska, mogu se uvesti, prethodno obraditi i pohraniti u vektorsku bazu podataka, koja olakšava integraciju s AI agentima.

Alat može generirati tekstualni sadržaj, uključujući blogove, opise proizvoda, vijesti i e-mailove, kao i multimedijski sadržaj poput slika i videozapisa temeljem korisničkih prompta. Platforma može biti implementirana u cloud-u ili na lokalnoj infrastrukturi, pružajući fleksibilnost korisnicima.

Promptly uključuje no-code graditelj, koji omogućuje kreiranje AI rješenja bez tehničkog znanja, povezujući LLM-ove s poslovnim procesima. Aplikacije i chatbotovi kreirani na platformi mogu se pokrenuti putem API-ja ili popularnih komunikacijskih alata poput Slack-a, WhatsApp-a ili Discord-a. Platforma podržava multi-tenant okruženje, omogućujući stvaranje više organizacija unutar iste instalacije, čime korisnici imaju pristup samo podacima specifičnim za svoju organizaciju. Promptly može biti implementiran u oblaku ili na lokalnoj infrastrukturi, ovisno o potrebama korisnika.

Promptly platforma omogućuje razvoj različitih AI aplikacija, od generativnih AI agenata do chatbotova. Agenti poput AI SDR-ova mogu generirati personalizirane e-mailove, LinkedIn poruke ili hladne pozive za prodajne timove. Platforma omogućuje istraživačkim analitičarima kreiranje izvještaja ili investicijskih teza, dok RPA automatizacije mogu automatizirati poslovne procese poput slanja e-mailova ili popunjavanja obrazaca. Osim toga, platforma podržava generiranje tekstualnog sadržaja, uključujući opise proizvoda, blog postove, vijesti i e-mailove.

Promptly omogućuje kreiranje chatbotova treniranih na korisničkim podacima, kao i generiranje multimedijskih sadržaja poput slika, videozapisa i audio materijala na temelju korisničkih prompta. Konverzacijska AI omogućuje razvoj sustava koji vode razgovore s korisnicima, dok AI sustavi za poboljšanje pretraživanja dodaju dodatne informacije pretraživačkim rezultatima putem API integracija. Slack i Discord botovi mogu se jednostavno integrirati i pokretati iz Promptly aplikacija putem no-code urednika.

Način izrade chatbota pomoću Promptly platforme i unaprijed definirane datoteke sa smjernicama je koristan pristup koji omogućuje izgradnju kontekstualno svjesnog i

prilagodljivog chatbota bez potrebe za složenim programiranjem. Ovaj pristup uključuje nekoliko ključnih koraka:

1. Priprema smjernica i podataka: Proces kreiranja chatbota započinje prikupljanjem svih potrebnih informacija i pisanjem smjernica u dokument. U ovoj datoteci definiraju se svi mogući korisnički upiti, odgovori i informacije o uslugama i proizvodima banke. Ove smjernice uključuju i važne teme, ključne riječi te upute kako chatbot treba odgovoriti na određena pitanja. Datoteka služi kao baza znanja i vodič za ponašanje chatbota.

2. Uvoz podataka u Promptly: Nakon pripreme smjernica, datoteka se uvozi u Promptly platformu. Promptly omogućuje uvoz podataka iz različitih formata, uključujući CSV, PDF, ili druge datoteke. Kada se podaci uvezu, Promptly automatski obrađuje sadržaj i pohranjuje ga u vektorsku bazu podataka. Ta baza podataka omogućuje brz i precizan pristup informacijama koje chatbot koristi tijekom interakcije s korisnicima.

3. Konfiguracija procesora: Nakon uvoza podataka, potrebno je konfigurirati procesore unutar Promptly platforme. Procesori, kao osnovni gradivni elementi chatbota, koriste podatke iz uvezene datoteke i jezične modele za obradu korisničkih unosa i generiranje odgovora. U ovoj fazi korisnik može dodati više procesora, npr. OpenAI ChatGPT, koji će omogućiti chatbotu da odgovara na različite vrste upita koristeći podatke iz datoteke.

4. Povezivanje s poslovnim procesima: Platforma Promptly omogućuje povezivanje procesora s različitim poslovnim procesima, poput slanja obavijesti ili promocije određenih bankarskih usluga. Na temelju smjernica iz datoteke, chatbot može automatski prepoznati prilike za promociju proizvoda i usluga, te korisnicima ponuditi relevantne informacije.

5. Testiranje i prilagodba: Kada je chatbot konfiguriran, može se testirati unutar Promptly okruženja. Kroz testiranje se provjerava kako chatbot reagira na različite upite i jesu li svi odgovori u skladu s definiranim smjernicama. Na temelju rezultata testiranja, moguće je ažurirati datoteku sa smjernicama i prilagoditi ponašanje chatbota, čime se osigurava visoka razina točnosti i relevantnosti odgovora.

6. Pokretanje i integracija: Nakon uspješnog testiranja, chatbot se može pokrenuti i integrirati u različite komunikacijske kanale, poput web stranica, aplikacija, ili platformi poput Slacka i WhatsAppa. Promptly omogućuje jednostavnu integraciju putem API-ja, što omogućava chatbotu pristup podacima u stvarnom vremenu i pružanje odgovora 24/7.

Ovaj pristup izrade chatbota omogućuje fleksibilnost i skalabilnost jer sve promjene u smjernicama mogu biti jednostavno ažurirane u datoteci, koja se zatim ponovno uvozi u Promptly. Na taj način, chatbot uvijek može biti ažuriran s najnovijim informacijama i strategijama za interakciju s korisnicima.

5.2.3. Koncepti i funkcionalnosti platforme

Koncepti koje je važno razlikovati su procesori, aplikacije i izvori podataka.

Procesori su osnovni elementi Promptly platforme koji omogućuju obradu unosa od korisnika ili drugih procesora u lancu, izvršavanje radnji i, ako je potrebno, generiranje odgovora. Platforma dolazi s nekoliko ugrađenih procesora, poput OpenAI-evog ChatGPT-a ili generiranja slika putem Stability AI. Alati su posebni procesori koji se koriste za izvršavanje određenih zadataka unutar agenata, kao što je primjerice generiranje eseja pomoću ChatGPT-a.

Pružatelji usluga (engl. *providers*) omogućuju funkcionalnost procesora, pri čemu se OpenAI API koristi za generiranje teksta, dok Promptly nudi integracije s više pružatelja poput OpenAI, Cohere i Stability AI.

Aplikacije su krajnji proizvod koji se kreira povezivanjem više procesora zajedno, a Promptly nudi vizualni urednik za jednostavnu izradu takvih aplikacija. Te aplikacije se mogu pokrenuti putem API-ja, korisničkog sučelja ili integracija sa Slack-om i Discord-om.

Agenti su autonomne aplikacije koje koriste procesore kao alate za izvršavanje zadataka, poput slanja e-mailova potencijalnim klijentima.

Izvori podataka (engl. *datasources*) omogućuju aplikacijama rad s vašim podacima, a Promptly podržava uvoz podataka iz različitih izvora, uključujući *CSV*, *PDF* i *URL*-ove, Google disk, te automatski obrađuje i pohranjuje te podatke u vektorsku bazu podataka.

Povezivanja (engl. *connections*) koriste se za pohranu šifriranih vjerodajnica za vanjske usluge poput baza podataka ili API-ja, dok varijable omogućuju dinamičku interakciju unutar aplikacija pružajući procesorima prilagodljive podatke, poput korisničkog imena.

Promptly također nudi razne alate kao što su App Builder za izradu AI aplikacija, Playground za testiranje procesora i Jobs za pokretanje aplikacija sa skupom ulaznih podataka.

5.2.4. Identifikacija funkcionalnosti

Za izradu marketinškog chatbota za Privrednu banku Zagreb, potrebno je identificirati specifične funkcionalnosti koje će chatbot omogućiti korisnicima, s naglaskom na promociju usluga i pomoć u odabiru odgovarajućih proizvoda. Ovaj chatbot neće samo odgovarati na često postavljena pitanja, već će aktivno promovirati proizvode i usluge banke, usmjeravajući korisnike prema najboljim opcijama za njihove potrebe.

Prva ključna funkcionalnost je pružanje personaliziranih preporuka. Korisnik će, na temelju unosa svojih preferencija ili ciljeva (npr. štednja, kreditiranje, investicije), dobiti preporuku o uslugama koje najbolje odgovaraju njegovim potrebama. Ova personalizacija se temelji na analizi podataka i mogućnostima integracije s bazama podataka o proizvodima banke.

Druga važna funkcionalnost je promocija aktualnih ponuda i proizvoda banke. Chatbot će aktivno predstavljati i promovirati sezonske ili posebne ponude (npr. akcijske kamatne stope na kredite, specijalne štedne pakete), kao i proizvode koje banka želi staviti u fokus. Ovo će omogućiti banki povećanje korisničkog angažmana i bolje informiranje klijenata.

Treća funkcionalnost odnosi se na interaktivno vođenje korisnika kroz proces odabira usluge. Chatbot će nuditi jednostavan dijalog u kojem će korisnicima postavljati pitanja kako bi suzio mogućnosti i omogućio im lakši izbor usluga. Na primjer, ako korisnik razmatra otvaranje štednog računa, chatbot će ga voditi kroz opcije različitih štednih planova i predložiti najpogodniju opciju.

Četvrta funkcionalnost uključuje povezanost s vanjskim sustavima i alatima. Kako bi chatbot bio što korisniji, potrebno je osigurati integraciju s vanjskim alatima, poput CRM sustava, kako bi mogao preuzeti relevantne informacije o korisniku te na temelju toga davati preporuke ili odgovore.

Na kraju, važno je osigurati dostupnost chatbot usluge na različitim platformama, uključujući web stranicu banke, mobilnu aplikaciju te popularne komunikacijske alate poput WhatsApp-a ili Slack-a, kako bi korisnici mogli komunicirati s chatbotom putem kanala koji im najviše odgovaraju.

Ove funkcionalnosti zajedno će omogućiti učinkovito promoviranje bankarskih usluga i osigurati da korisnici dobivaju prave informacije i preporuke u stvarnom vremenu.

5.2.5. Sučelje i arhitektura sustava

Dijelovi chatbota su jednostavni za pojmiti i sučelje je intuitivno.

Na početnoj stranici susrećemo se s Aplikacijama, primjeri ugrađenih aplikacija su: Prevoditelj, Lista želja, Glasovni chat i tako dalje. Stranica s aplikacijama je prva stranica koju vidite kada se prijavite na Promptly. Daje vam brzi pregled vaših aplikacija koje posjedujete, kao i aplikacija koje su podijeljene s vama.

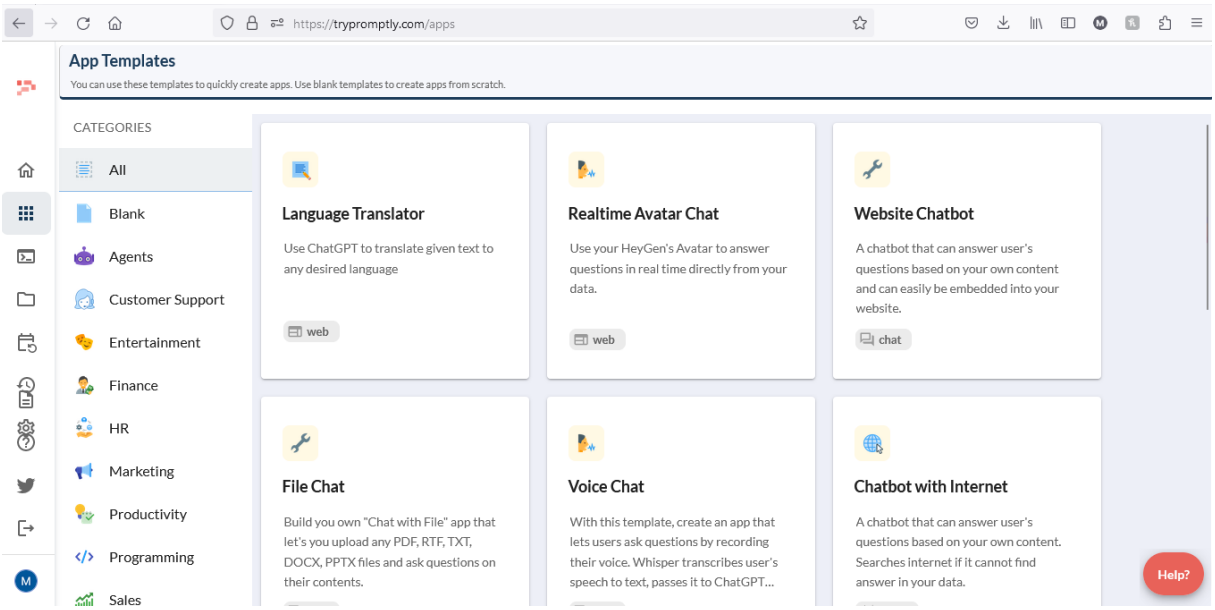

Slika 1.: Početna stranica

Zatim, stranica „App Builder“ omogućuje vam izradu moćnih AI aplikacija koristeći Promptly. Možete povezati više procesora, dodati izvore podataka, dijeliti aplikacije, integrirati aplikacije s vanjskim uslugama i implementirati svoje aplikacije u proizvodnju. Također možete verzije svojih aplikacija, testirati ih i dijeliti sa svojim timom.

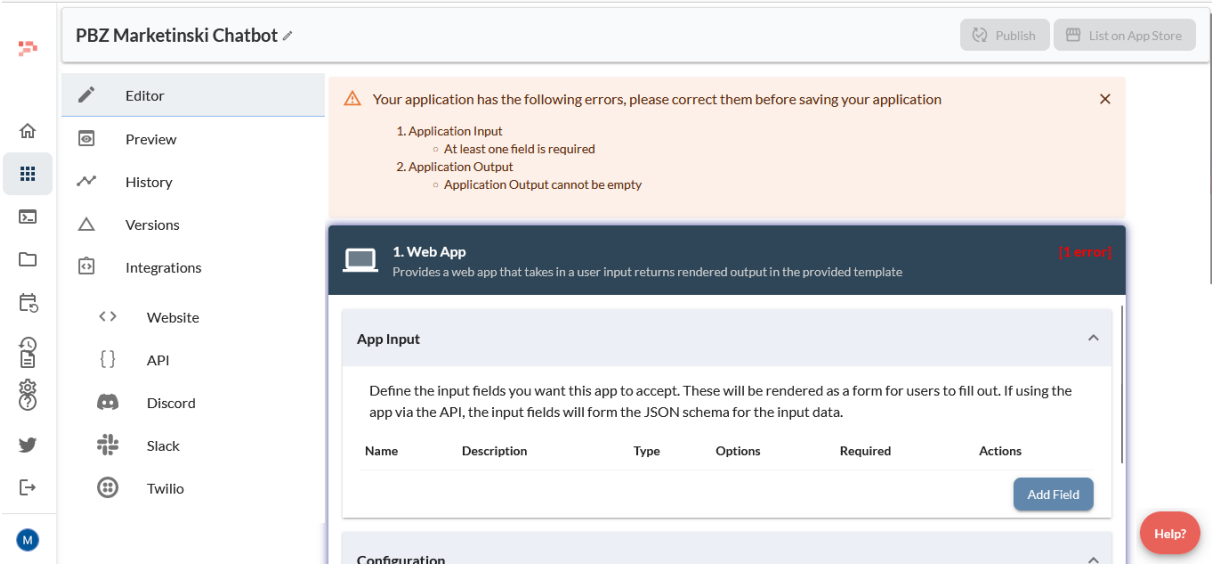

Slika 2.: App Builder

Dodatno, stranica *Playground* omogućuje testiranje svih dostupnih procesora u Promptlyju. Procesore možete testirati vlastitim unosom i konfiguracijom prije nego što ih

upotrijebite u svojim aplikacijama. Također stranica *History* koja je prikaz svih spremljenih verzija aplikacija.

Odabrala sam Web App i imenovala aplikaciju „PBZ Marketinški Chatbot“. Sada smo u uređivaču aplikacije.

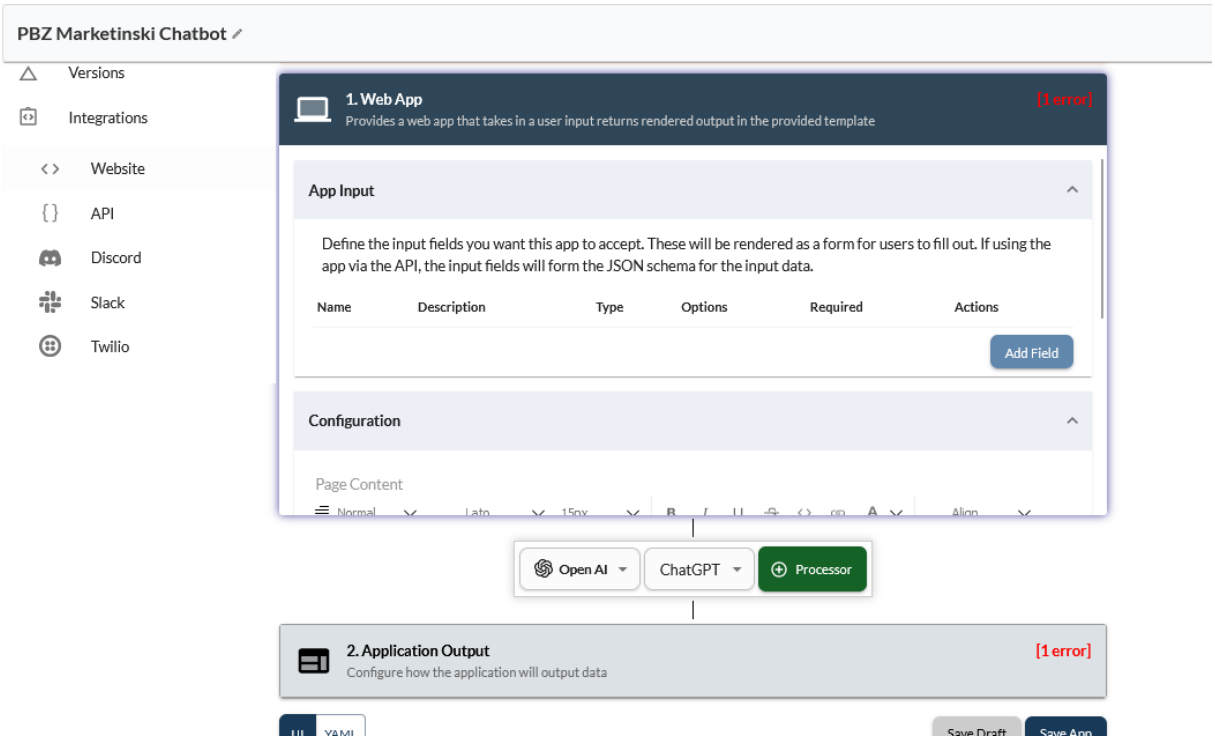

Slika 3.: Odabir naziva aplikacije

Potrebno je popuniti polje *App Input*, odnosno ulazno polje za korisnički unos, polja se prilagođavaju pomoću „Add Field“. Ta ulazna polja predstavljaju obrasce, forme koje korisnici ispunjavaju prilikom interakcije s chatbotom.

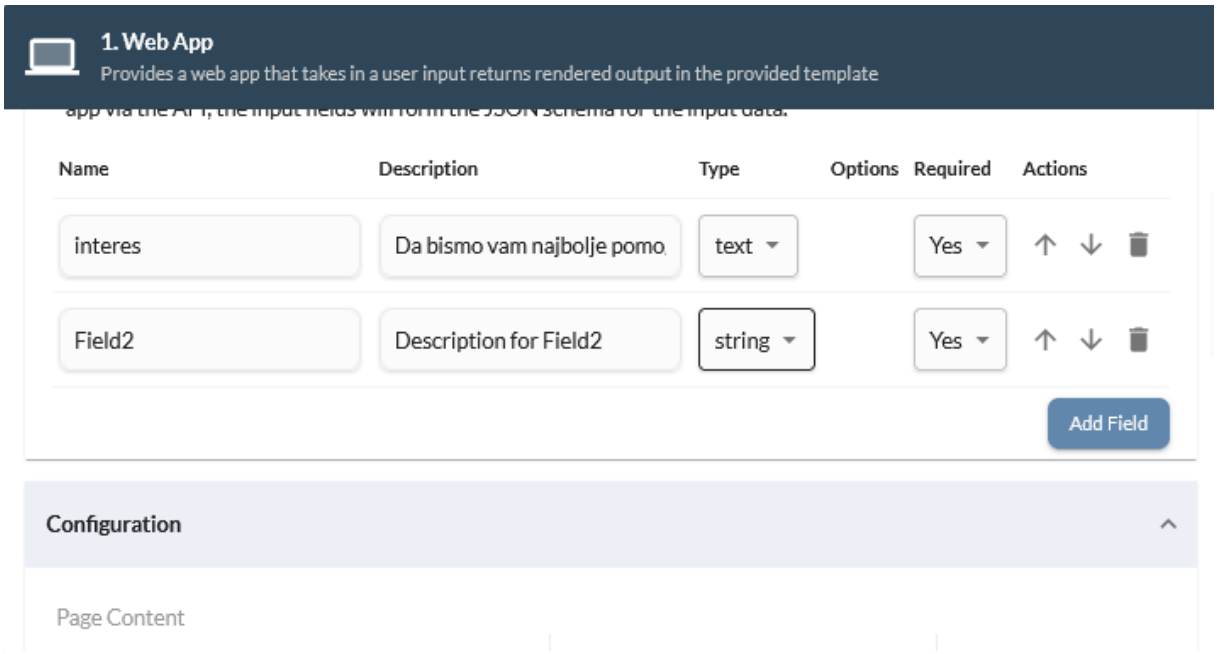

Slika 4.: Dodavanje ulaznih polja

Konfiguracijom ulaznih polja za web aplikaciju dodajemo „interes“ uz opis koji implicira da korisnici trebaju unijeti informaciju o interesu kako bi chatbot pružio personaliziranu informaciju ili prijedlog o bankarskoj usluzi. Tip polja je „text“, dakle, korisnici unose slobodan tekst kao odgovor. Također, polje je obavezno za ispunjavanje, što je označeno opcijom "Yes" pod kategorijom "Required." Ova postavka omogućuje korisnicima interakciju s chatbotom na način da unesu specifične podatke o svojim interesima ili potrebama, što chatbot zatim koristi za prilagodbu odgovora i pružanje relevantnih informacija o bankarskim proizvodima.

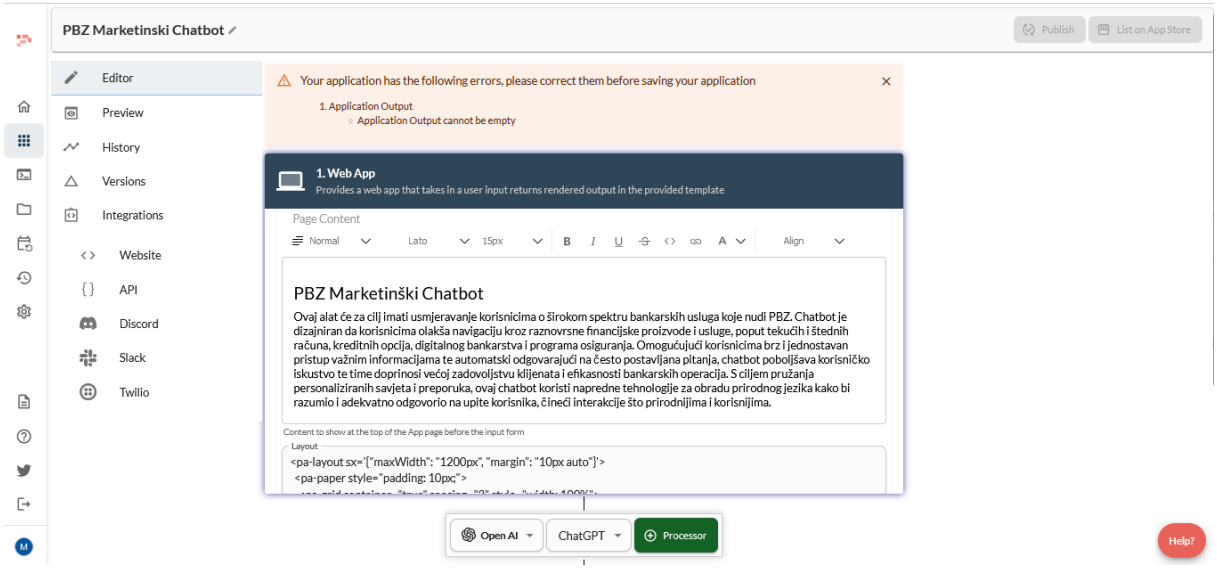

Slika 5.: Konfiguracija odjeljka Page Content

Odjeljak „Page Content“ sadrži tekst koji opisuje PBZ Marketinški Chatbot, a pruža informacije o tome kako će chatbot korisnicima olakšati pristup bankarskim uslugama i odgovarati na njihove upite. Tekstualni opis naglašava glavne funkcionalnosti chatbota, uključujući personalizirane preporuke, mogućnost brze obrade podataka i podršku za korisnike u realnom vremenu.

Moj opis aplikaciji je „*Ovaj alat će biti učinkovit sučelje za korisnike u širokom spektru bankarskih usluga koje nudi PBZ. Chatbot je dizajniran da olakša pristup informacijama kao i preporuke financijskih proizvoda, poput različitih bankovnih računa i kredita, digitalnih bankarskih usluga i osiguranja. Omogućit će korisnicima personalizirane preporuke na temelju njihovih potreba i upita u stvarnom vremenu. Chatbot će također integrirati umjetnu inteligenciju za identificiranje i razumijevanje korisničkih potreba kroz prirodni jezik. Cilj ovog alata je poboljšati korisničko iskustvo, optimizirati operacije banke i omogućiti bržu i učinkovitiju interakciju s korisnicima. Chatbot će biti dostupan putem web stranice banke kao i različitih aplikacija kako bi korisnici dobili brze odgovore na svoje upite, čime je značajno skraćeno vrijeme čekanja*.“.

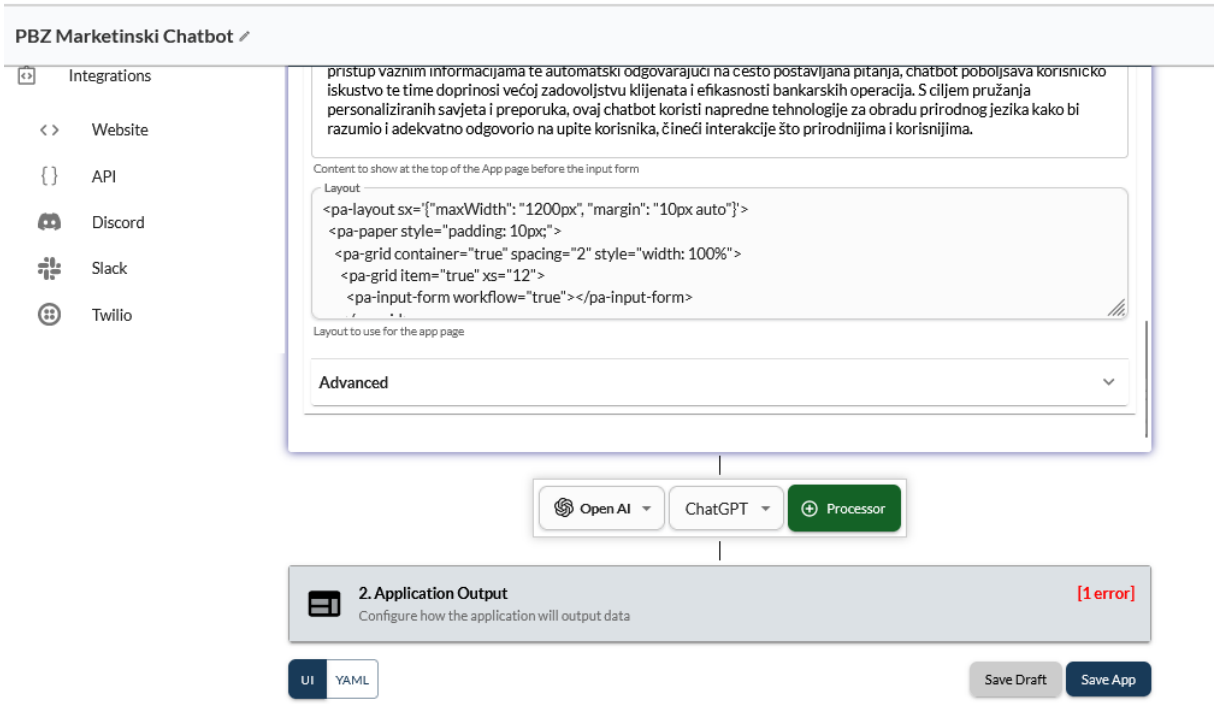

Slika 6.: Veza između *App Input* i *App Output*

Vidimo da je ovdje uključen dio koda koji specificira izgled i strukturu stranice koristeći HTML/CSS stilove. Na primjer:

- <pa-layout> definira širinu i margine stranice.
- <pa-paper> određuje padding (unutarnji razmak) od 10px.

Ostale oznake <pa-grid> i <pa-input-form> koriste se za definiranje rasporeda i formi koje korisnik treba ispuniti na web stranici.

U srednjem dijelu sučelja vidimo opciju za procesiranje sadržaja koristeći OpenAI ili ChatGPT, što sugerira da je AI integriran za generiranje odgovora ili obrade unosa korisnika.

Na dnu sučelja nalazi se sekcija "Application Output," gdje se definira kako će aplikacija prikazivati rezultate ili odgovore korisnicima.

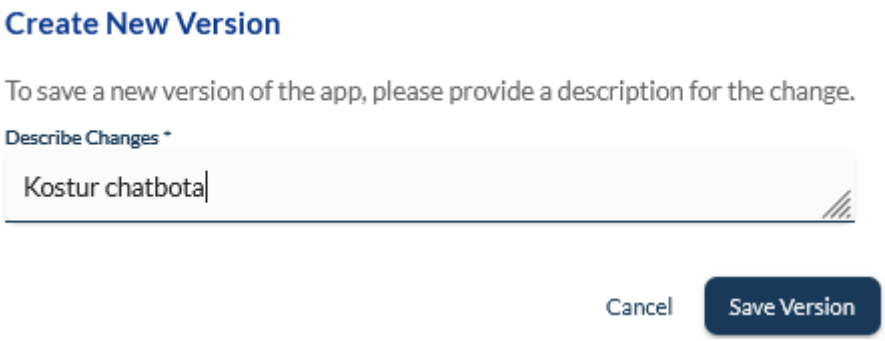

Slika 7.: Spremanje prve verzije

Na slici je prikazan prozor unutar alata Promptly za stvaranje nove verzije aplikacije. Prozor nosi naslov "Create New Version" (Stvori novu verziju) i omogućava korisniku da spremi promjene na aplikaciji pružajući opis tih promjena.

U polju za opis promjena ("Describe Changes"), korisnik je unio tekst "Kostur chatbota," što sugerira da je trenutna verzija aplikacije osnovni ili početni okvir chatbota, bez detaljne funkcionalnosti, ali s definiranim osnovnim strukturama.

Na dnu su ponuđene dvije opcije:

- "Cancel" (Odustani) za izlaz bez spremanja,
- "Save Version" (Spremi verziju) za spremanje nove verzije s opisom koji je unesen.

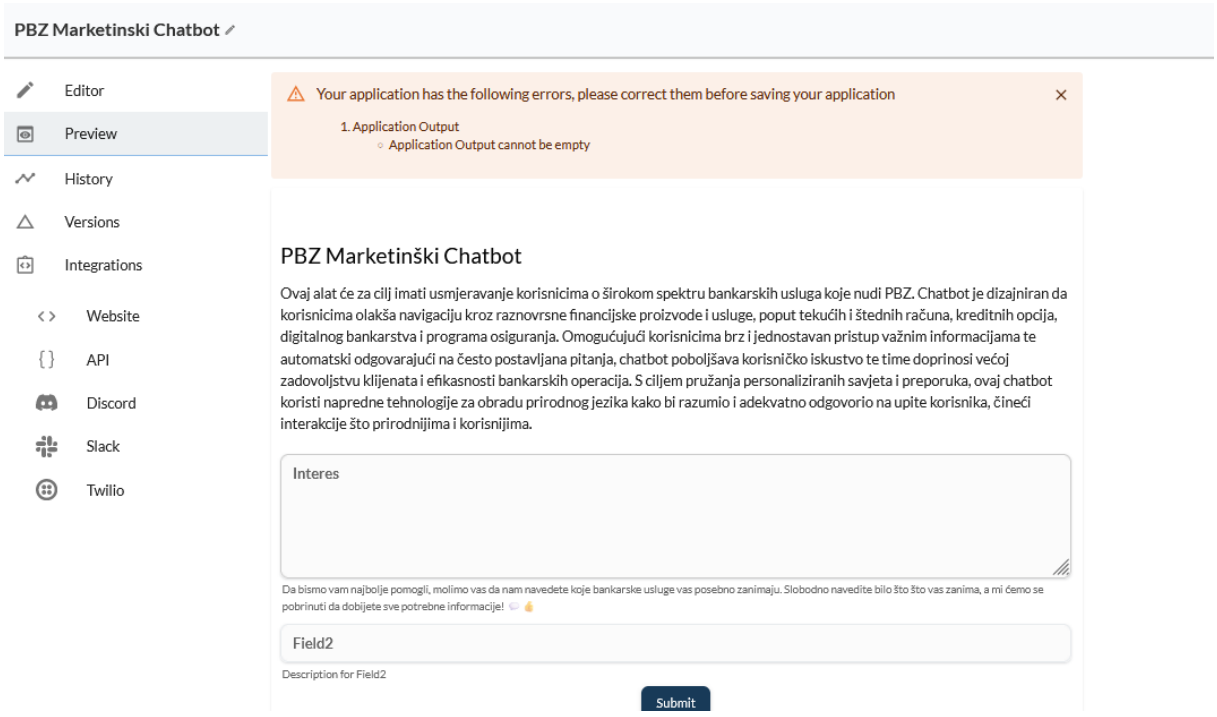

Slika 8.: Preview

U ovom je prozoru prikazan pretpregled aplikacije, odnosno kakav će prikaz imati korisnik. Pretpregled omogućava kreatoru aplikacije da vidi kako će korisničko sučelje izgledati te kako će korisnici unositi podatke i dobivati povratne informacije. Postoji naslov i opis koji objašnjava svrhu i glavne funkcionalnosti, te nakon polja za unos interesa stoji dodatni opis koji usmjeruje korisnike kako najbolje ispuniti polje.

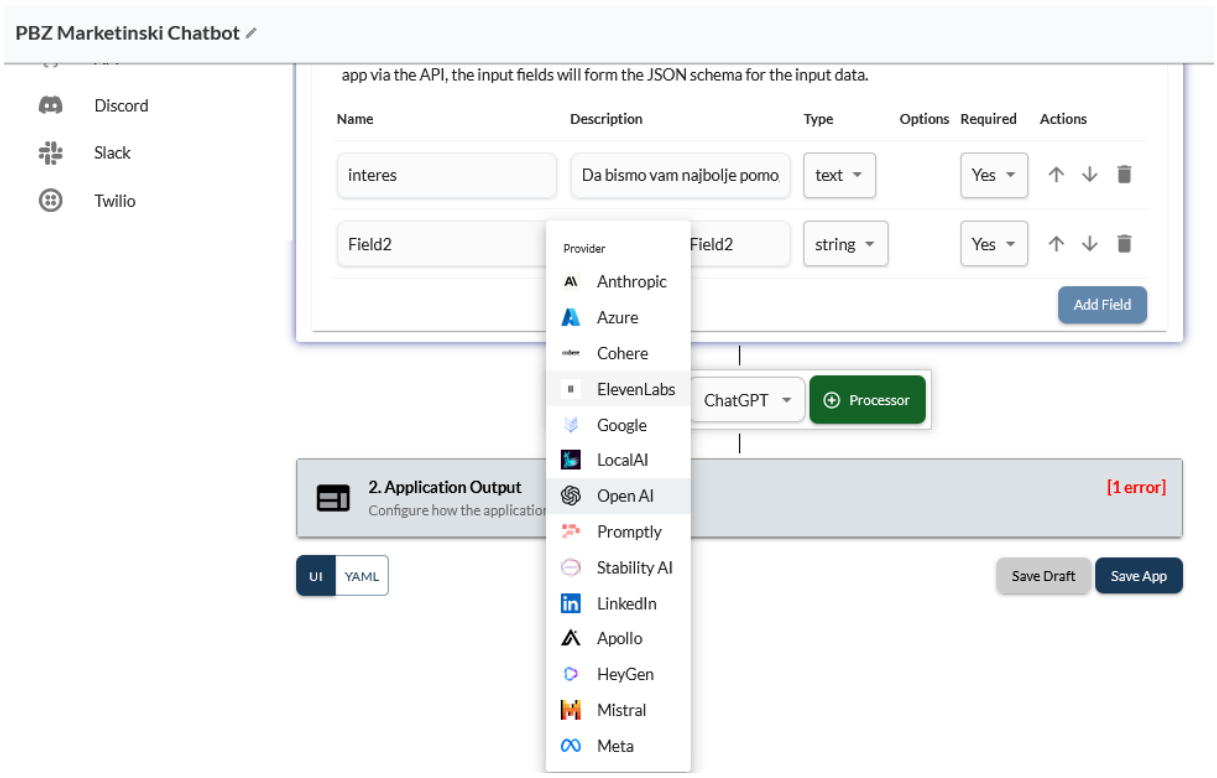

Slika 9.: *Provider*

Provider izbornik, odnosno lista različitih pružatelja usluga umjetne inteligencije koji mogu biti korišteni za procesiranje korisničkih unosa. Odabran je ChatGPT kao procesor, a ostale opcije su Anthropic, Azure, Cohere, ElevenLabs, Google, Promptly i sl. Ova opcija ima za svrhu odabir željenog modela umjetne inteligencije za obradu korisničkih upita i generiranje odgovora u aplikaciji.

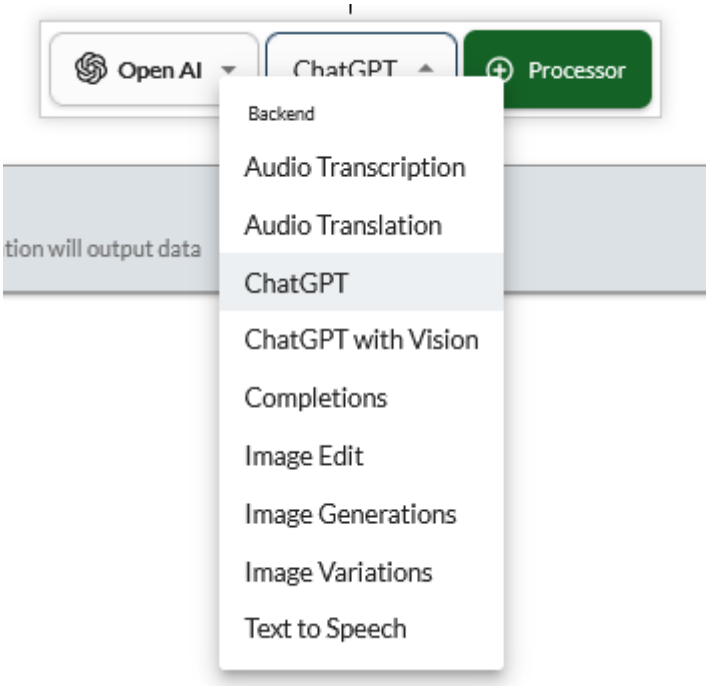

Slika 10.: *Processor*

Odabir je između razmičitih mogućnosti procesora OpenAI. Odabrana je opcija ChatGPT, model koji je zadužen za obradu korisničkih upita i generiranja odgovora u aplikaciji. Ovaj izbornik omogućava kreatoru aplikacije da odabere specifične funkcionalnosti AI-a kako bi chatbot mogao bolje odgovarati na potrebe korisnika, bilo kroz tekst, slike ili zvuk.

Dostupne opcije u izborniku uključuju:

- Audio Transcription: Pretvaranje audio zapisa u tekst.
- Audio Translation: Prevođenje audio sadržaja s jednog jezika na drugi.
- ChatGPT: Standardna verzija ChatGPT-a za tekstualnu interakciju.
- ChatGPT with Vision: Opcija koja omogućuje razumijevanje i generiranje odgovora uz pomoć vizualnog inputa.
- Completions: Generiranje završetka teksta ili rečenica na temelju korisničkog unosa.
- Image Edit: Uređivanje slika pomoću AI-a.

- Image Generations: Generiranje novih slika iz opisa.
- Image Variations: Stvaranje varijacija postojećih slika.
- Text to Speech: Pretvaranje tekstualnog sadržaja u govor.

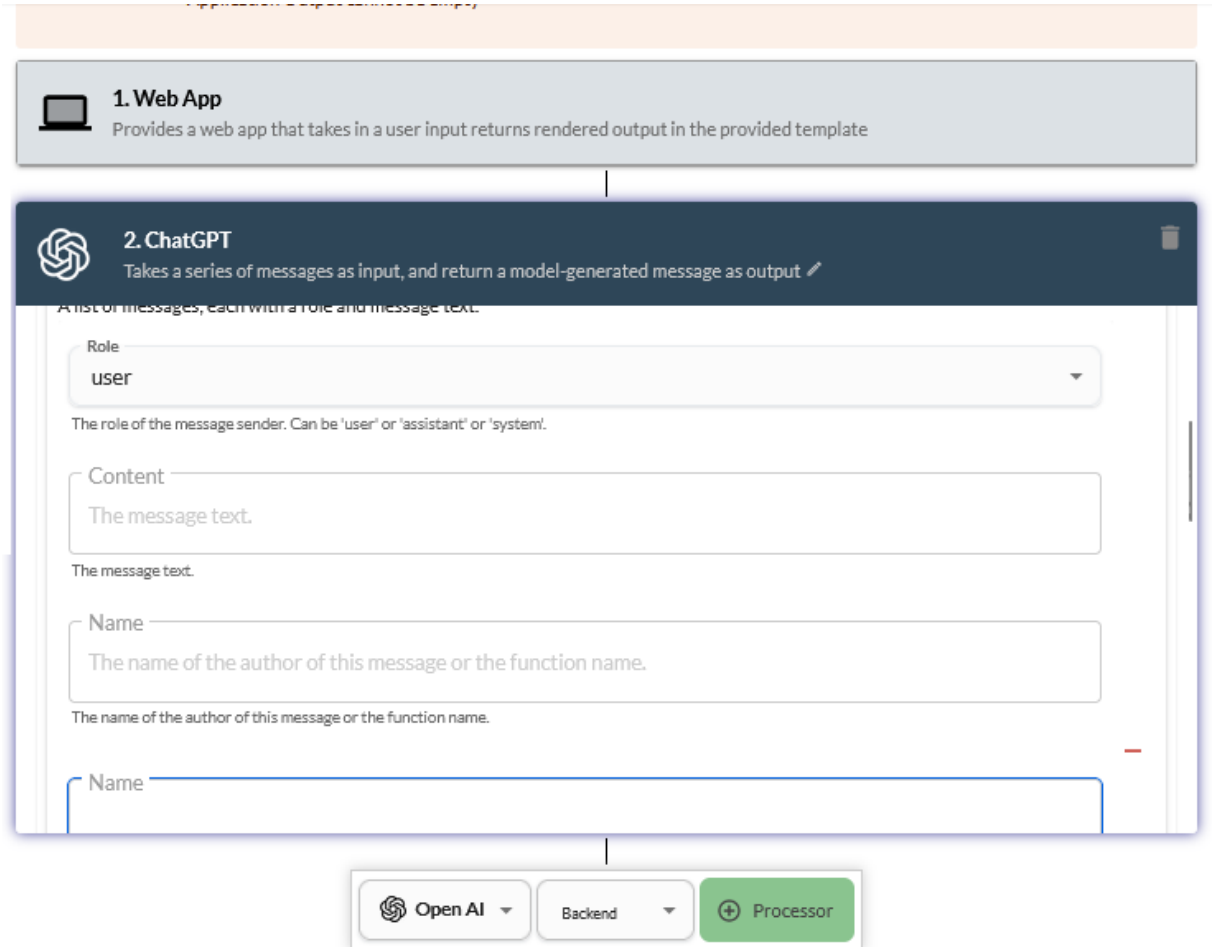

Slika 11.: Prozor ChatGPT 1.0

U prozoru „2. ChatGPT“ je odjeljak za postavljanje parametara unutar AI chatbot modula. Prikazani su elementi sučelja, uključujući mogućnost postavljanja uloga korisnika, pisanja sadržaja poruka, te definiranje imena autora ili funkcije. Sučelje omogućuje postavljanje parametara koji definiraju kako će chatbot obrađivati i odgovarati na korisničke upite. U donjem dijelu slike vidljiva su dva gumba "Open AI" i "Processor" koji služe za pokretanje obrade zadatka putem umjetne inteligencije.

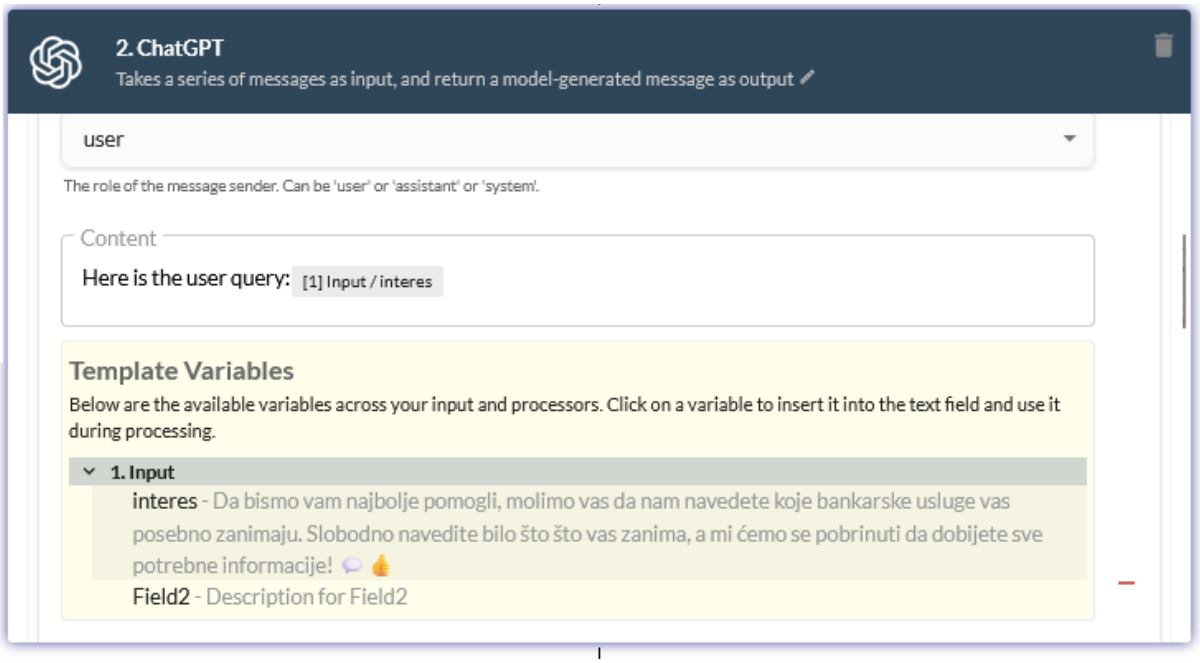

Slika 12.: Prozor ChatGPT 2.0

Ova slika prikazuje dio za definiranje ulaznih podataka i varijabli za chatbot. Prikazano je područje za unos korisničkog upita s postavljenom varijablom "interes", koja omogućava korisniku da navede koje bankarske usluge ga zanimaju. U opisu stoji da korisnik može slobodno navesti što želi, a chatbot će pružiti relevantne informacije. Ovaj dio sučelja također sadrži popis dostupnih varijabli koje se mogu koristiti tijekom obrade upita.

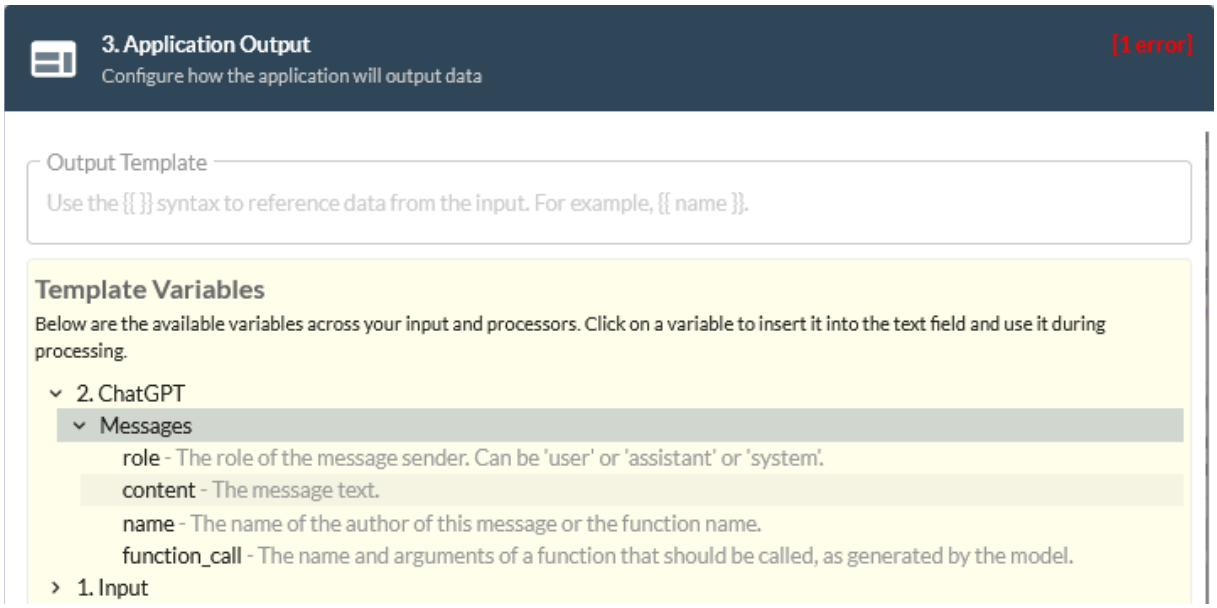

Slika 13.: Prikaz izlaza

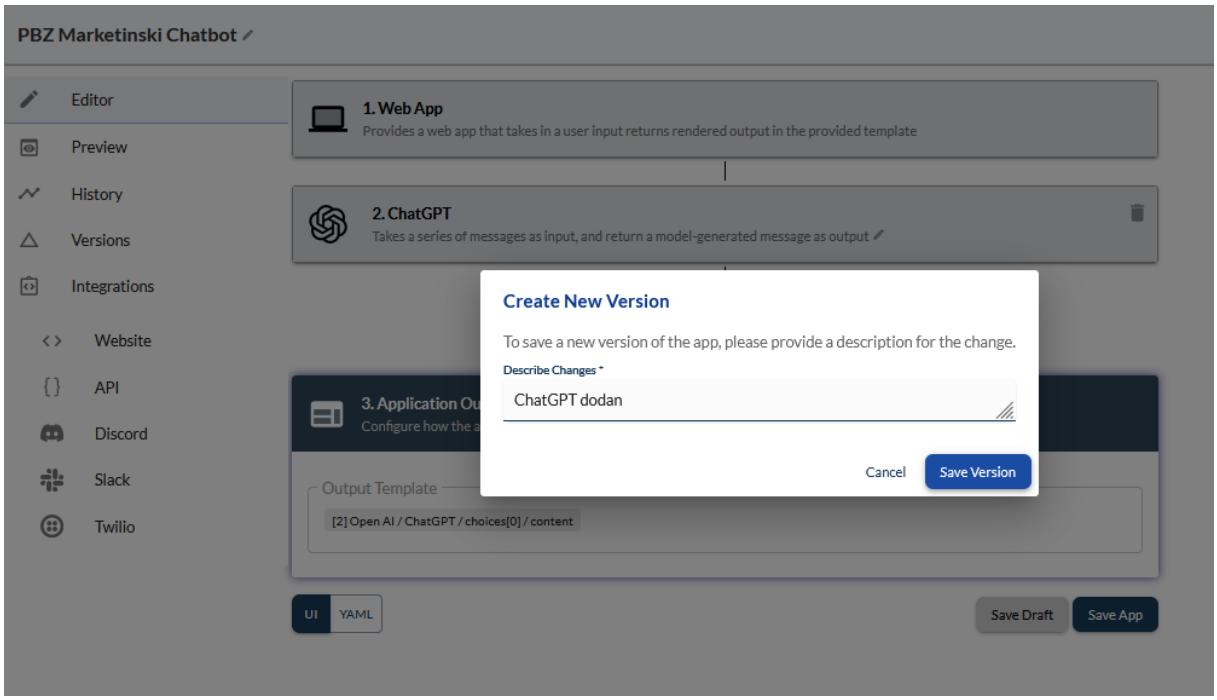

Slika 14.: Spremanja verzije

Ova slika prikazuje postupak spremanja nove verzije aplikacije u Promptly alatu. Unijela sam opis promjene pod nazivom "ChatGPT dodan", što označava da je integracija s ChatGPT-om dovršena i spremljena u novu verziju aplikacije. Prozor prikazuje mogućnost unosa opisa promjena za novu verziju aplikacije, a zatim gumb "Save Version" omogućuje spremanje tih izmjena. U pozadini se vidi tijek aplikacije, s tri koraka: Web App, ChatGPT i Application Output, koji definiraju rad chatbota.

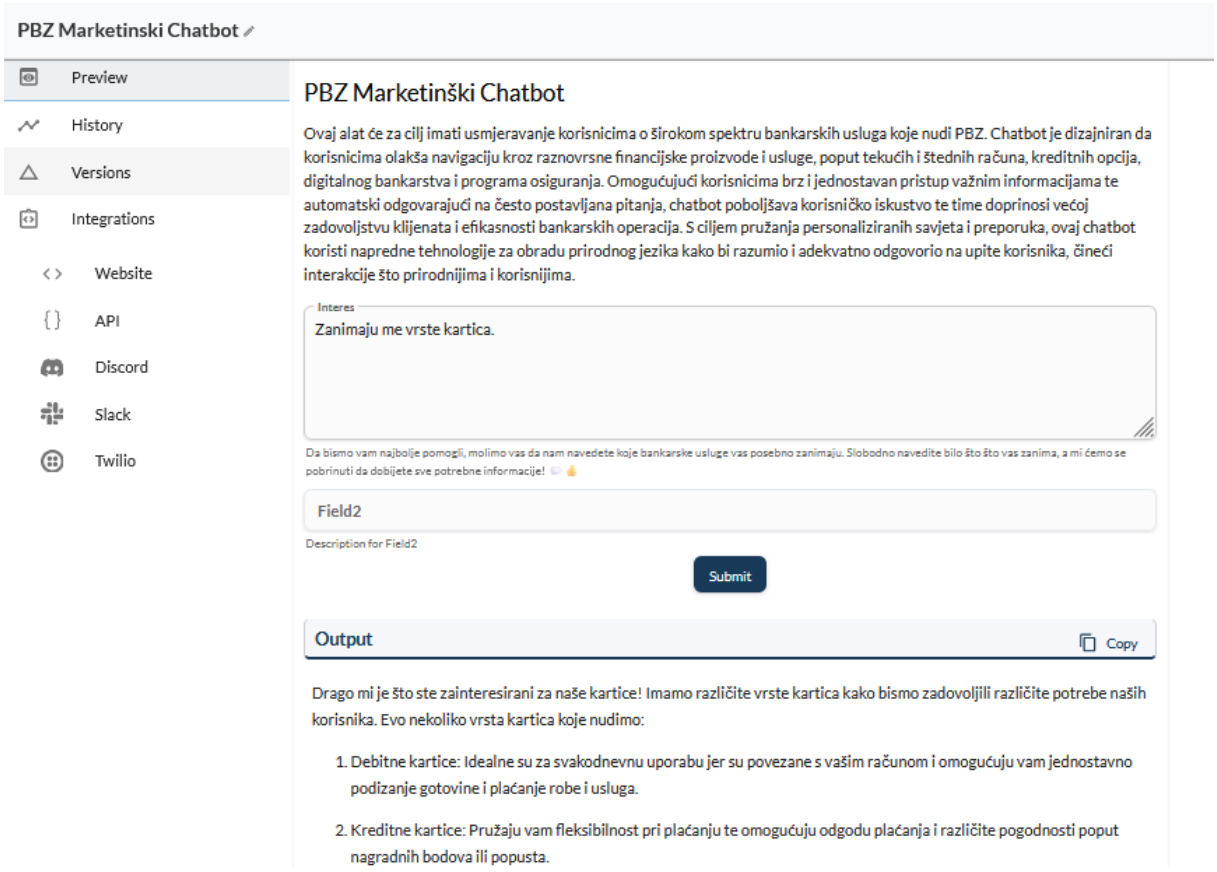

Slika 15.: Opis izlaza

Unijela sam u polje „Interes“ da me zanimaju vrste kartica i testirala izlaz. Kreirala sam sučelje koje korisnicima omogućuje interakciju s chatbotom, gdje mogu unijeti svoje interese, u ovom slučaju pitanje o vrstama kartica ("Zanimaju me vrste kartica"). Ispod toga nalazi se polje za unos korisničkog upita i gumb "Submit" za potvrdu upita. Na izlaznom dijelu (Output), chatbot odgovara korisniku s detaljima o dostupnim vrstama kartica, pružajući korisne informacije o debitnim i kreditnim karticama.

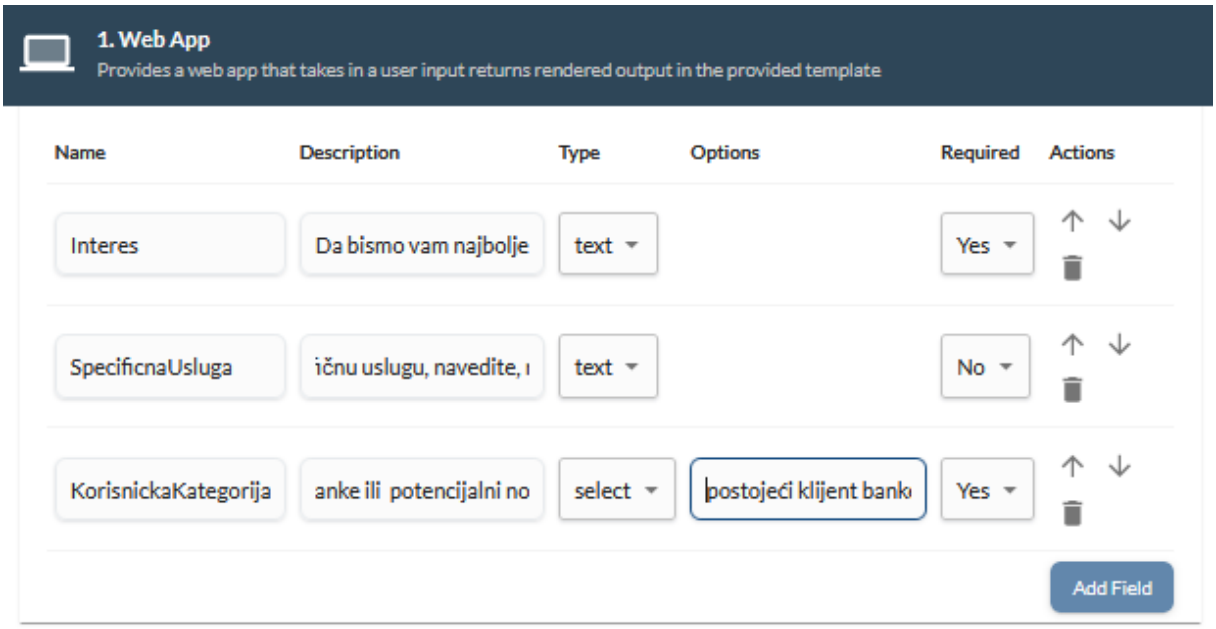

Slika 16.: Unos dodatnih ulaza

U ovom koraku definiram ulazne varijable koje korisnici trebaju unijeti kako bi chatbot mogao pružiti odgovore. Polja uključuju "Interes" (tekstualno polje), "Specifična Usluga" (tekstualno polje) i "Korisnička Kategorija" (odabir iz padajućeg izbornika). Svako polje ima opciju da bude obavezno ("Yes" ili "No"), a možeš ih uređivati, dodavati nova polja i mijenjati redoslijed kako bi prilagodila formu potrebama korisnika.

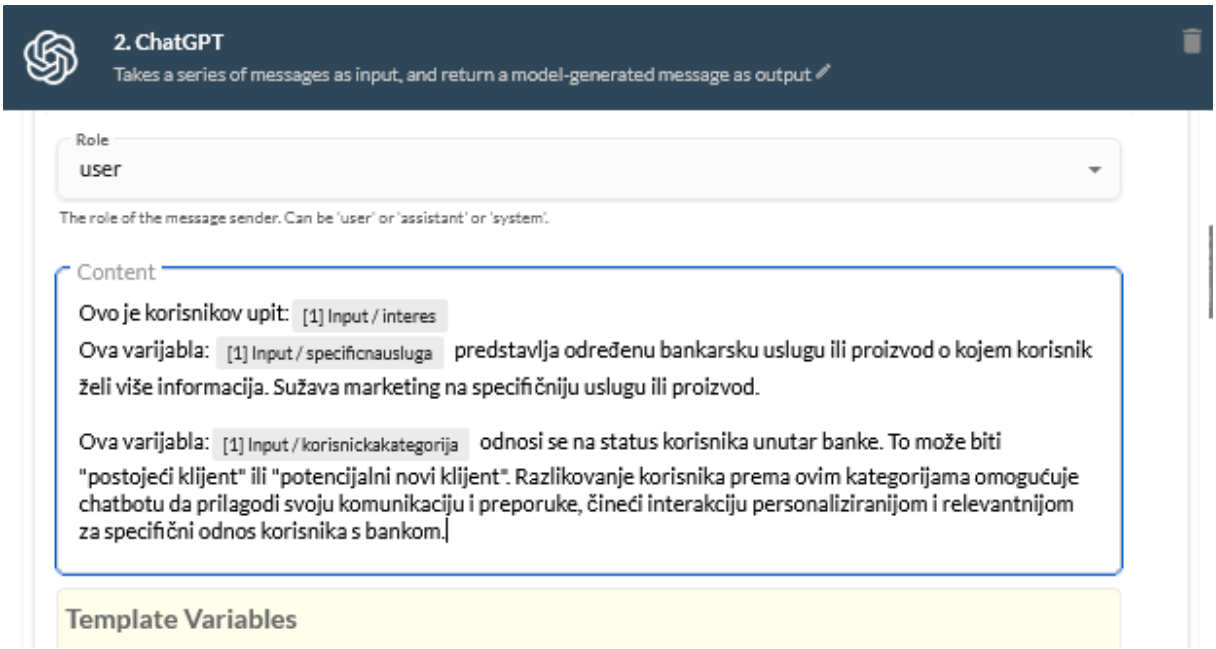

Slika 17.: Dodavanje sadržaja

Postavljen je korisnički upit koji uključuje varijable "Interes", "Specifična Usluga" i "Korisnička Kategorija" koja nudi izbor između dvije opcije. Tekst objašnjava svrhu svake varijable. "Interes" odnosi se na određenu bankarsku uslugu ili proizvod o kojem korisnik želi

informacije. "Specifična usluga" sužava marketing na određeni proizvod, dok "Korisnička kategorija" identificira korisnika kao postojećeg ili potencijalnog klijenta, što omogućuje personaliziranu interakciju chatbota s korisnikom na temelju njihovog statusa unutar banke.

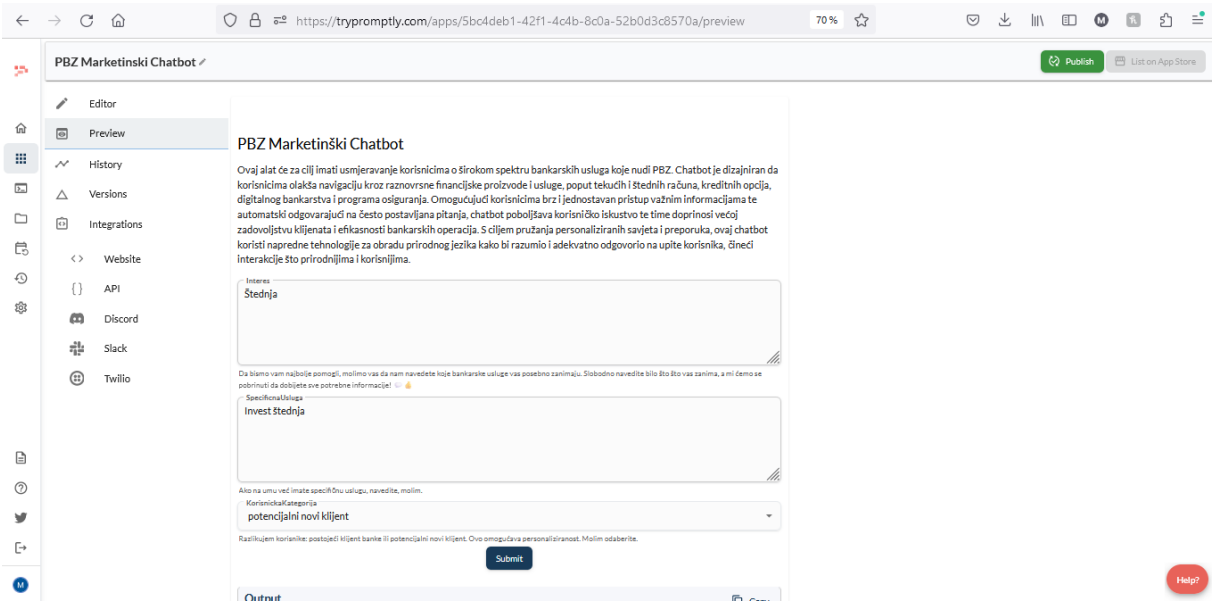

Slika 18.: Pretpregled

Nakon dodavanja sadržaja, testiramo dosada kreirano tako da unosimo primjer pretrage korisnika, a na sljedećoj slici je izlaz. U gornjem dijelu prozora nalazi se opis ciljeva i funkcionalnosti chatbota, koji pomaže korisnicima da se lakše informiraju o bankarskim uslugama. Korisnik unosi podatke u polja kao što su "*Služba*" i "*Interesi*", a chatbot na temelju tih informacija generira personalizirane odgovore. U donjem dijelu ekrana nalazi se gumb za slanje upita, što omogućava korisnicima interakciju s chatbotom i dobivanje relevantnih informacija.

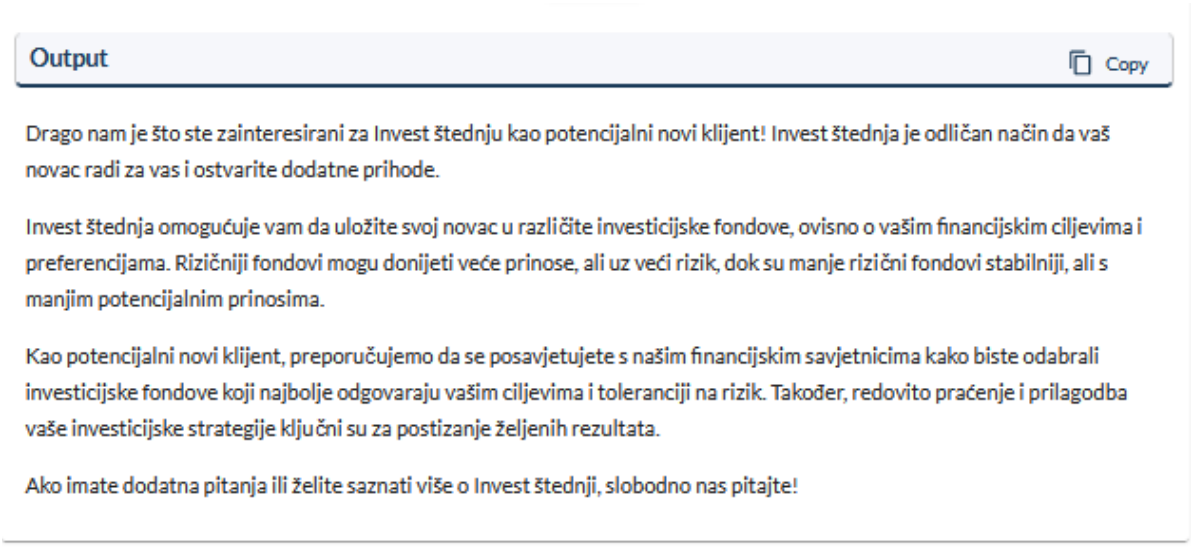

Slika 19.: Izlaz za primjer

Ova slika prikazuje izlazni prozor ("*Output*") u kojem chatbot odgovara korisniku na upit o Invest štednji. Chatbot korisniku objašnjava osnovne karakteristike Invest štednje kao potencijalnom novom klijentu, ističući prednosti poput mogućnosti ulaganja u različite investicijske fondove. Također, spominje rizike povezane s većim i manjim prinosima te preporučuje konzultacije s financijskim savjetnikom kako bi se odabrao odgovarajući fond. Na kraju odgovora, chatbot poziva korisnika da slobodno postavi dodatna pitanja ako želi saznati više o Invest štednji.

Version	Comment
v5	Dodana baza znanja
v4	Više upita i padajući izbornik
v3	Više inputa i padajući izbornik
v2	Više inputa i padajući izbornik
v1	ChatGPT dodan
v0	Kostur chatbota

Slika 20.: Popis svih spremljenih verzija chatbota

Ova slika prikazuje popis različitih verzija chatbota unutar Promptly alata, s napomenama o promjenama unesenim u svakoj verziji. Verzija „v0“ prikazuje početni "Kostur chatbota", dok je u verziji „v1“ dodan ChatGPT. Verzije „v2“ do „v4“ uključuju dodavanje više

ulaza i padajućih izbornika, a u verziji „v5“ je dodana baza znanja, što vjerojatno poboljšava sposobnost chatbota da odgovara na složenije upite korisnika.

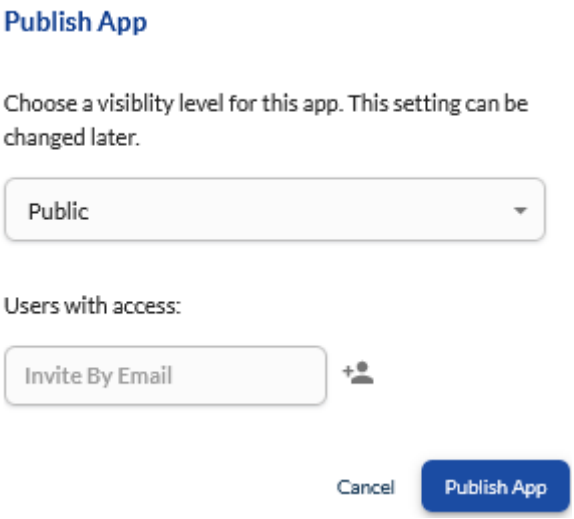

Slika 21.: Izmjena vidljivosti aplikacije

Ovaj prozor prikazuje korak za objavljivanje aplikacije u Promptly alatu. Korisnik može odabrati razinu vidljivosti aplikacije, koja je postavljena na "*Public*" (javno dostupna), što znači da će aplikacija biti dostupna svima. Također, postoji opcija za pozivanje određenih korisnika putem e-maila za pristup aplikaciji. Na dnu prozora nalazi se gumb "*Publish App*" koji potvrđuje objavu aplikacije.

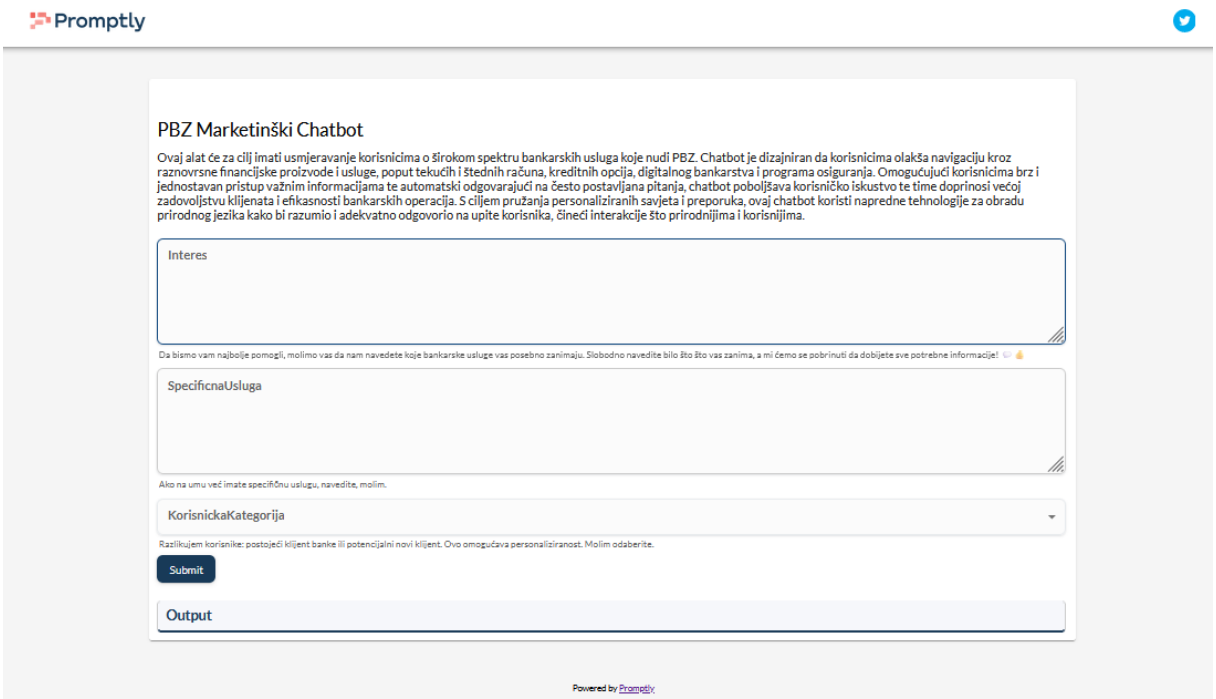

Slika 22.: Pretpregled chatbot aplikacije u alatu Promptly

Ova slika prikazuje gotov pregled aplikacije "PBZ Marketinški Chatbot" unutar Promptly alata. U aplikaciji korisnici mogu unijeti svoje interese, specifične usluge koje ih zanimaju i odabrati kategoriju korisnika (npr. postojeći ili potencijalni klijent). Na temelju tih unosa, chatbot će generirati personalizirani odgovor. Aplikacija je dizajnirana kako bi olakšala korisnicima pristup informacijama o raznim bankarskim uslugama, omogućujući jednostavnu i intuitivnu interakciju putem teksta. Na dnu je gumb "*Submit*" za slanje upita i polje "*Output*" za prikaz rezultata.

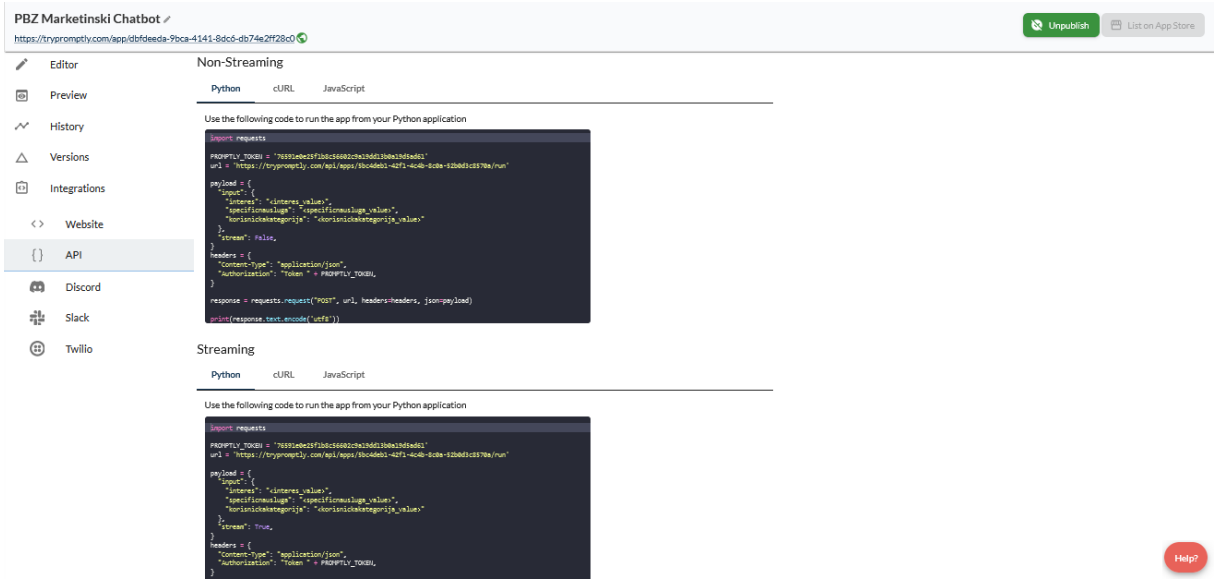

Slika 23.: Integracija

Ova slika prikazuje API integraciju za "PBZ Marketinški Chatbot" unutar Promptly alata. Vidljiva su dva segmenta koda za *Python* aplikacije, jedan za *Non-Streaming* i drugi za *Streaming* način rada. Ovi primjeri koda omogućuju povezivanje vanjskih aplikacija s chatbotom putem API-ja, koristeći HTTP zahtjeve za slanje i primanje podataka između aplikacije i chatbota. Na lijevoj strani sučelja nalazi se izbornik za navigaciju kroz različite sekcije.

Promptly platforma, osim glavne "*Editor*" kartice, nudi i druge funkcionalne kartice za lakše upravljanje i testiranje AI aplikacija. Kartica *Preview* omogućuje pregled aplikacije kako bi korisnici mogli testirati njezin izgled i funkcionalnost pomoću definiranih ulaznih podataka i procesora. *History* sadrži zapis svih pokretanja aplikacije ili testova provedenih u "*Playground-u*", omogućavajući analizu ponašanja aplikacije kroz pregled ulaza, izlaza i dodatnih informacija za svaku interakciju. Kartica Versions služi za upravljanje različitim verzijama aplikacije, što je korisno za spremanje, testiranje i vraćanje na prethodne verzije, olakšavajući razvoj i optimizaciju. Integrations nudi mogućnosti povezivanja aplikacije s

vanjskim komunikacijskim kanalima, uključujući web stranicu, API, *Slack*, *Discord* i *Twilio*, čime omogućuje izvođenje radnji i komunikaciju kroz razne platforme.

5.2.6. Prototip

Prototip predstavlja rani model ili verzija proizvoda koja pokazuje osnovnu funkcionalnost i služi kao osnova za testiranje i evaluaciju.

Da bismo testirali PBZ Marketinški Chatbot, možemo unijeti podatke u sva tri polja koja su prikazana na slici. Testiranje bi se sastojalo od sljedećeg:

- Polje "Interes": Ovdje korisnik može unijeti svoje interese u vezi s bankarskim uslugama. Primjer unosa može biti "Zanimaju me opcije štednje i investicijski fondovi".

- Polje "SpecifičnaUsluga": Ovo polje je za slučajeve kada korisnik već ima na umu specifičnu uslugu. Na primjer, korisnik može unijeti "Kredit za stanovanje".

- Polje "KorisničkaKategorija": Korisnik može birati između opcija koje definiraju njegov status, primjerice "Postojeći klijent" ili "Novi klijent". Ovo omogućuje chatbotu personalizaciju odgovora na temelju korisničke kategorije.

Nakon unosa informacija, klikom na gumb "Submit" pokreće se chatbot, koji na temelju unesenih podataka generira odgovore i informacije o bankarskim uslugama. Ovaj proces predstavlja fazu testiranja prototipa aplikacije, čime se može utvrditi njena funkcionalnost i sposobnost pružanja relevantnih informacija korisnicima.

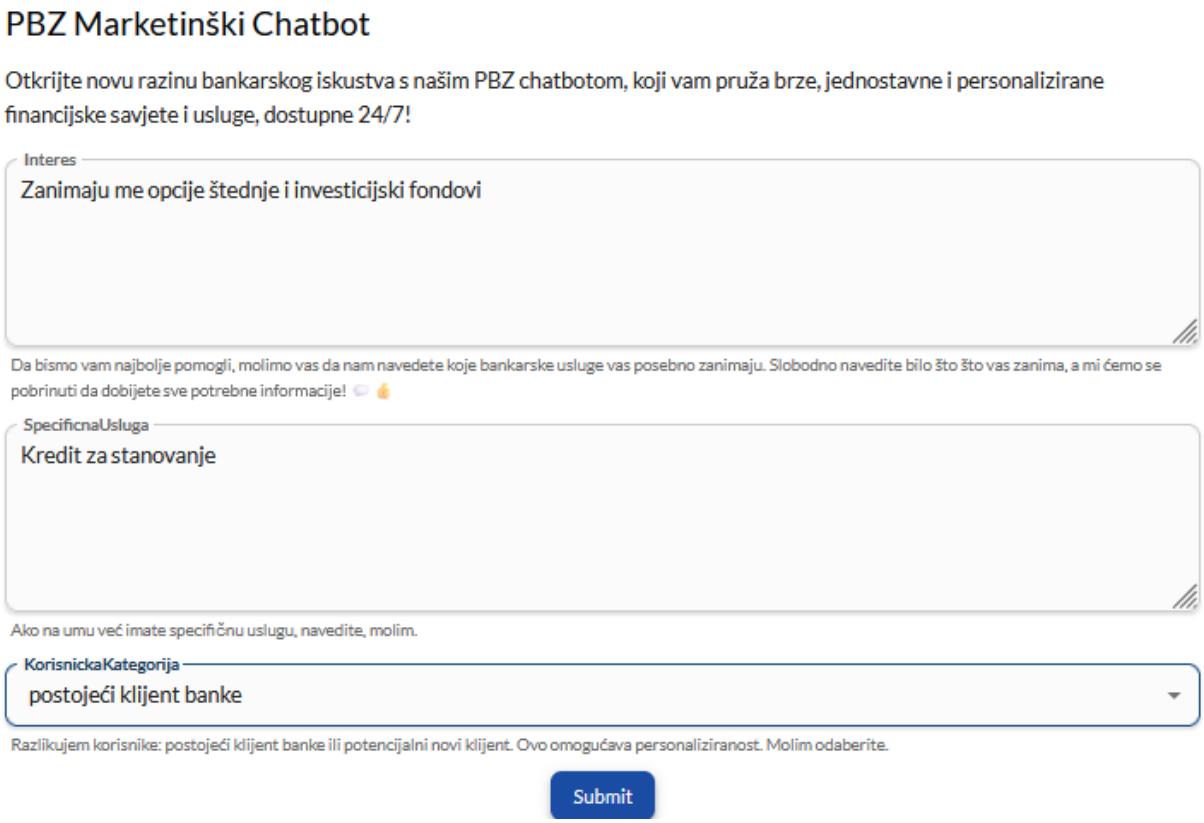

Slika 24. Testiranje chatbota i unos

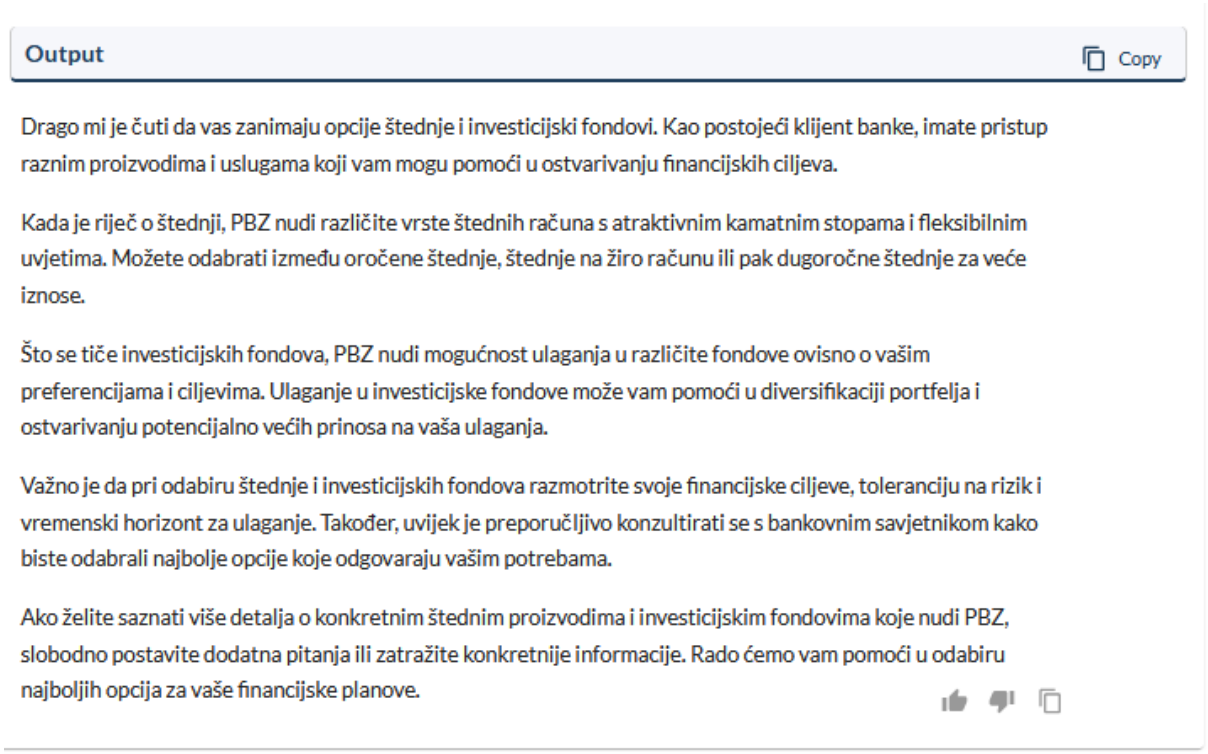

Slika 25. Testiranje chatbota i izlaz

Nakon unosa korisničkih podataka i interesa za bankarske usluge, chatbot generira personalizirani odgovor. U ovom slučaju, chatbot je odgovorio na upit o opcijama štednje i investicijskim fondovima, prilagođavajući informacije postojećem klijentu banke.

Tekstualni odgovor uključuje opis dostupnih vrsta štednje koje PBZ nudi, poput oročene štednje i štednje na žiro računu, te daje preporuke vezane za ulaganje u investicijske fondove. Chatbot savjetuje korisnika da razmotri svoje financijske ciljeve i preporučuje konzultaciju s bankovnim savjetnikom radi donošenja najboljih odluka. Ovaj primjer pokazuje sposobnost chatbota da pruži relevantne, ciljne informacije na temelju korisničkog interesa, čime doprinosi korisničkom iskustvu i podržava marketinške aktivnosti banke.

U ovom slučaju, prototip PBZ Marketinškog chatbota prikazuje ključne značajke: korisničko sučelje, unos podataka, te generiranje personaliziranih odgovora na upite. Output prikazan na slici demonstrira chatbot-ovu sposobnost da obradi korisnikov unos i pruži relevantne informacije, što je cilj marketinškog chatbot-a. Iako se radi o osnovnoj verziji, prototip jasno ilustrira funkcionalnost i način na koji će chatbot komunicirati s korisnicima.

Prema izvorima kao što su Buttle i Maklan[4], funkcionalno testiranje obuhvaća unos raznovrsnih upita kako bi se ocijenila chatbotova sposobnost razumijevanja i preciznog odgovaranja na korisničke upite. Ovo uključuje provjeru ponašanja chatbota kada obavezna polja nisu ispunjena ili kada su unosi netočni. Testiranje otpornosti chatbota na takve situacije osigurava da sustav može pružiti korisne povratne informacije korisnicima, kao što preporučuje Ashfaq i suradnici [15].

Korisničko iskustvo je ključni faktor u procjeni učinkovitosti chatbota. Jiménez-Barreto, Rubio i Molinillo [3] ističu važnost prikupljanja povratnih informacija korisnika kako bi se analizirala lakoća korištenja i zadovoljstvo dobivenim odgovorima. Provođenje A/B testiranja s različitim verzijama chatbota može pomoći u identifikaciji najbolje opcije za korisničko iskustvo, kao što sugerira Campbell i suradnici [11].

Scenarijsko testiranje, koje se može naći u istraživanju Belle Church [10], omogućuje procjenu učinkovitosti chatbota u različitim situacijama, uključujući odgovaranje na specifična pitanja o bankarskim uslugama.

Integracija chatbota s vanjskim bazama podataka je također kritična. Kako navode Alt i Reinhold [12], testiranje integracija osigurava da chatbot pruža točne i ažurirane informacije korisnicima. Kroz unos namjerno nejasnih ili netočnih upita, chatbot se može testirati na otpornost na greške, kako bi se procijenila njegova sposobnost traženja dodatnih informacija ili pružanja alternativnih odgovora, što je važno za održavanje profesionalnog korisničkog iskustva [16].

5.3. Unaprijeđeni chatbot

Korisnici su klijenti i potencijalni klijenti banke, ljudi koji jednostavno istražuju tržište. Zahjtevi variraju od traženja generičkih informacija do preciznih pitanja o konkretnoj usluzi.

Kreirani konverzacijski agent nije samo alat za pružanje informacija; on djeluje kao virtualni promotor banke, unaprjeđujući korisničko iskustvo i podržavajući poslovne ciljeve. Chatbot komunicira s korisnicima i potencijalnim klijentima, pružajući odgovore na različita pitanja - od općih informacija o bankarskim uslugama do specifičnih upita o proizvodima poput kredita ili investicija. Time se korisnicima omogućuje lakše donošenje odluka i upoznavanje s ponudom banke, bez potrebe za čekanjem na telefonsku podršku ili posjetom poslovnici. Na taj način chatbot postaje ključni element u digitalnoj transformaciji poslovanja, omogućujući brzo i personalizirano korisničko iskustvo, dok istovremeno pomaže u smanjenju operativnih troškova i poboljšanju učinkovitosti banke.

Moj marketinški chatbot unaprijeđen je u odnosu na trenutni PBZ-ov chatbot kroz nekoliko ključnih aspekata:

- Personalizirana promocija: Dok trenutni PBZ-ov chatbot pruža odgovore na generička pitanja i nudi informacije o bankarskim proizvodima, moj chatbot koristi napredne algoritme za analizu korisničkih upita i povijesti interakcija. Na taj način može preporučiti proizvode i usluge koje su specifično prilagođene potrebama svakog korisnika. Ovaj personalizirani pristup omogućuje učinkovitije promicanje proizvoda i veći angažman korisnika.
- Kontekstualna svjesnost: Unaprijeđeni chatbot ima ugrađene značajke koje mu omogućuju prepoznavanje konteksta i ton korisničkih upita. Koristeći veliku jezičnu podršku (LLM), chatbot može voditi složenije i prirodnije razgovore, interpretirati različite varijante pitanja i prilagoditi odgovore na temelju konteksta.
- Multimedijska interakcija: Osim tekstualnih odgovora, moj chatbot može generirati multimedijski sadržaj poput slika, videozapisa i audio materijala. Ovaj napredak u interakciji čini komunikaciju s korisnicima dinamičnijom i zanimljivijom.
- Brža obrada podataka: Koristeći Promptly platformu, moj chatbot je sposoban integrirati se s različitim izvorima podataka (npr. CSV, PDF, Google Disk) i koristiti vektorske baze podataka za brzu obradu informacija. To omogućuje pružanje preciznih i detaljnih odgovora u stvarnom vremenu, čime se značajno poboljšava korisničko iskustvo.
- Automatizacija i proaktivnost: Moj chatbot nije samo reaktivan na upite; može proaktivno nuditi informacije i promocije na temelju analiziranih podataka o korisnicima. Ovo uključuje slanje personaliziranih e-mailova, marketinških poruka ili obavijesti korisnicima, čime se potiče veći angažman i lojalnost prema banci.

- Fleksibilnost i integracija: Novi chatbot je fleksibilniji i može se integrirati s različitim komunikacijskim kanalima (*Slack, WhatsApp, Discord*). Također, može se pokrenuti putem API-ja, što omogućuje jednostavnu implementaciju u postojeće digitalne sustave banke.

Ove nadogradnje čine izrađeni marketinški chatbot naprednijim i prilagodljivijim potrebama korisnika, te osiguravaju bolju promociju bankarskih proizvoda i usluga.

6. Zaključak

Kroz analizu, uočeno je da chatbot ima potencijal poboljšati korisničko iskustvo pružajući relevantne informacije o proizvodima u stvarnom vremenu. Također, njegova prednost leži u mogućnosti pružanja podrške bez prestanka te automatizaciji promotivnih aktivnosti. Prototip je zamišljen da bude fleksibilan i lako prilagodljiv različitim komunikacijskim kanalima, uključujući web-stranice i aplikacije. Iako nije izvršeno praktično testiranje, teorijska analiza sugerira da bi ovaj chatbot mogao značajno unaprijediti korisničku podršku i marketing bankarskih usluga.

Upotreba Promptly alata omogućila je povezivanje chatbota s bazom znanja, što je ključ za generiranje točnih i relevantnih odgovora u stvarnom vremenu. S obzirom na mogućnost uvoza različitih izvora podataka i rad s vektorskim bazama podataka, chatbot je sposoban obrađivati i analizirati korisničke upite učinkovito, pružajući personalizirane informacije. Ova tehnologija također olakšava buduća ažuriranja i proširenja funkcionalnosti, čineći chatbot dugoročno održivim i skalabilnim rješenjem.

Zaključno, Promptly alat i umjetna inteligencija pokazali su se ključnim za razvoj modernog marketinškog chatbota. No, iako alat pruža brojne prednosti, važna je i daljnja evaluacija kako bi se osigurala optimalna ravnoteža između automatizacije i ljudske interakcije te prevladali potencijalni izazovi, poput percepcije umjetnosti interakcije ili ograničenja u razumijevanju složenih upita.

Preporučljivo je analizirati u kojem opsegu se razgovorni agent implementira i za koji aspekt poslovanja. Dakle, zaključak je da za zadatke manje kompleksnosti, razgovorni agent služi bolje nego stvarna osoba, nema reda čekanja niti radnog vremena primjerice. Suprotno, za zadatke više razine kompleksnosti, korisnici smatraju stvarnu osobu superiornijom nad tehnologijom. Također je preporuka da služe kao dodatak, nikako kao zamjena za tradicionalnu potporu korisnicima. Implementacijom se smanjuju operativni troškovi, no može nositi društveni trošak, odnoseći se na širi utjecaj djelovanja, primjerice negativan učinak na zapošljavanje novih zaposenika, privatnost i tako dalje.

Međutim, postoje i određena ograničenja u korištenju chatbotova. Neki korisnici mogu smatrati da su interakcije s chatbotom umjetne ili neosobne, a postoji i rizik da chatbotovi možda neće u potpunosti razumjeti ili ispravno odgovoriti na složenije ili suptilnije upite. Kako bi se prevladao ovaj problem, neki istraživači su predložili novu metodu za prepoznavanje emocija korisnika tijekom razgovora, poput sreće, ljutnje, tuge, straha i neutralnih stanja. Uvođenjem analize osjećaja korisnika, značajno se povećava točnost chatbotova u

donošenju ispravnih odluka, čime se poboljšavaju ključni pokazatelji optimizacije korisničke usluge (KPI).

7. Popis literature

[1] A.l.i.c.e.chatbot. [Online]. Dostupno: http://www.alicebot.org/.

[2] S. Dahl, Social Media Marketing: Theories and Applications, 2nd ed., Sage, 2018. doi: 10.4135/9781473984066.n27.

[3] P. V. K. Bernoff and J., "The future of customer service is AI-Human Collaboration," MIT Sloan Management Review. [Online]. Dostupno na: https://sloanreview.mit.edu/article/the-future-of-customer-service-is-ai-human-collaboration/. Pristupljeno: srpanj 2024.

[4] F. Buttle and S. Maklan, Customer Relationship Management: Concepts and Technologies, London: Routledge, 2019. doi: 10.4324/9781351016551.

[5] A. Payne and P. Frow, "A Strategic Framework for Customer Relationship Management," Journal of Marketing, vol. 69, no. 4, pp. 167-176, 2006.

[6] K. Hosanagar, D. Lee, and H. S. Nair, "The Effect of Social Media Marketing Content on Consumer Engagement: Evidence from Facebook," Wharton School, 2013.

[7] W. Reinartz, M. Krafft, and W. Hoyer, "The Customer Relationship Management Process: Its Measurement and Impact on Performance," Journal of Marketing Research, vol. 41, no. 3, pp. 293-305, 2004. doi: 10.1509/jmkr.41.3.293.35991

[8] M. Gill, S. Sridhar, and R. Grewal, "Return on engagement initiatives: A study of a business-to-business mobile app," Journal of Marketing, vol. 81, no. 4, pp. 45-66, 2017, doi: 10.1509/jm.16.0149.

[9] J. Jiménez-Barreto, N. Rubio, and S. Molinillo, "'Find a flight for me, Oscar!' Motivational customer experiences with chatbots," International Journal of Contemporary Hospitality Management, vol. 33, no. 11, pp. 3860-3882, 2021.

[10] B. Church, "5 Types of Chatbot and How to Choose the Right One for Your Business," IBM Blog, rujan, 2023. [Online]. Dostupno na: https://www.ibm.com/think/topics/chatbot-types.

[11] C. Campbell, et al., "AI-based chatbots in customer service and their effects on user compliance," Electronic Markets, vol. 31, no. 3, pp. 729–743, 2021.

[12] R. Alt and O. Reinhold, Social Customer Relationship Management: Fundamentals, Applications, Technologies, Springer, 2020. [Online]. Dostupno na: https://doi.org/10.1007/978-3-030-23343-3.

[13] P. V. Kannan and J. Bernoff, The Age of Intent: Using Artificial Intelligence to Deliver a Superior Customer Experience, Amplify Publishing Group, 2019.

[14] M. Imperial, "Chatbot Implementation in Customer Service," Bachelor's thesis, JAMK University of Applied Sciences, Finland, 2023. [Online]. Dostupno na: https://www.theseus.fi/bitstream/handle/10024/784783/Imperial_Margie.pdf?sequence=2.

[15] M. Ashfaq, J. Yun, S. Yu, and S. Maria, "I, chatbot: Modeling the determinants of users' satisfaction and continuance intention of AI-powered service agents," Telematics and Informatics, vol. 54, p. 101473, 2020.

[16] C. Bishop, "Chatbots vs. conversational AI: What's the difference?" Zendesk, Jan. 26, 2024. [Online]. dostupno: https://www.zendesk.com.

[17] D. Khurana, A. Koli, K. Khatter, and S. Singh, "Natural language processing: State of the art, current trends, and challenges," Multimedia Tools and Applications, vol. 82, pp. 3713-3744, 2022.

[18] L. Vishnoi, "Chatbot vs. Live Chat: Which One Is Better for Your Business?" Acquire, 2021. [Online]. Dostupno na: https://acquire.io/blog/chatbot-vs-live-chat/.

[19] D. Dobrinić and I. Gregurec, Ponašanje potrošača, Varaždin: Fakultet organizacije i informatike, 2016, pp. IX, 416.

[20] Zendesk, "Chatbots vs. conversational AI: What's the difference?" Zendesk, 2024. [Online]. Dostupno na: https://www.zendesk.com

[21] A. Rončević, "NOVE USLUGE BANKARSKOGA SEKTORA: RAZVITAK SAMOPOSLUŽNOGA BANKARSTVA U HRVATSKOJ", Ekonomski pregled, vol.57, br. 11, str. 753-776, 2006. [Online]. Dostupno na: https://hrcak.srce.hr/8518.

[22] M. Malla, "SBI Customers Perception on CRM: A Study," Asia Pacific Journal of Marketing & Management Review, vol. 1, no. 3, 2012.

[23] Promptly. "Promptly Platform - Build and Integrate AI Agents." [Online]. Dostupno na: https://promptly.ai/.

[24] "PBZ | Građani," *Privredna banka Zagreb*. https://www.pbz.hr/gradjani

[25]

8. Popis slika

Slika 1.: Početna stranica.....15
Slika 2.: App Builder.....16
Slika 3.: Odabir naziva aplikacije.....16
Slika 4.: Dodavanje ulaznih polja.....17
Slika 5.: Konfiguracija odjeljka Page Content.....18
Slika 6.: Veza između *App Input* i *App Output*.....19
Slika 7.: Spremanje prve verzije.....20
Slika 9.: *Provider*.....21
Slika 10.: *Processor*.....22
Slika 11.: Prozor ChatGPT 1.0.....23
Slika 12.: Prozor ChatGPT 2.0.....24
Slika 13.: Prikaz izlaza.....24
Slika 14.: Spremanja verzije.....25
Slika 15.: Opis izlaza.....26
Slika 16.: Unos dodatnih ulaza.....27
Slika 17.: Dodavanje sadržaja.....27
Slika 18.: Pretpregled.....28
Slika 19.: Izlaz za primjer.....29
Slika 20.: Popis svih spremljenih verzija chatbota.....29
Slika 21.: Izmjena vidljivosti aplikacije.....30
Slika 22.: Pretpregled chatbot aplikacije u alatu Promptly.....30
Slika 23.: Integracija.....31
Slika 24. Testiranje chatbota i unos.....33
Slika 25. Testiranje chatbota i izlaz.....33