

Nevzudin Buzadija

Denis Čeke

Naida Bikić

**STRUKTURIRANA UPOTREBA GENERATIVNE VJEŠTAČKE INTELIGENCIJE U
SOFTVERSKOM INŽENJERSTVU: ANKETNA ANALIZA I FUZZY-GENETSKI
MODEL ZA PEDAGOŠKU INTERVENCIJU**

Sažetak

Masovna upotreba generativne vještačke inteligencije u obrazovanju softverskog inženjerstva zahtijeva pristup koji istovremeno omogućava iskorištavanje prednosti alata i sprječava prekomjerno oslanjanje studenata na automatizirana rješenja. U ovom radu kombinujemo anketno istraživanje provedeno među studentima ($N = 79$) i hibridni fuzzy–genetski (GA) model odlučivanja koji kvantificira potrebu za pedagoškom intervencijom kao funkciju učestalosti upotrebe i percipiranog rizika. Neparometrijska analiza ukazuje na statistički značajne razlike u odnosu na karijerne orijentacije ($H = 14,192$; $p = 0,028$) i obrasce učestalosti korištenja, pri čemu intenzivniji korisnici primjenjuju alate u širem spektru aktivnosti (učenje programskih jezika, generisanje rješenja i razvoj prototipova). Fuzzy sistem zasnovan na devet pravila i trapeznim/trougaonim funkcijama pripadnosti defuzificira izlaz na skali 0–10 („nisko“ do „urgentno“), dok genetski algoritam (GA) optimizira granice funkcija pripadnosti i pragove odlučivanja. Optimizirani model ostvaruje nisku prosječnu grešku predikcije i konzistentno identificira scenarije „visoka izloženost + (umjeren ili visok) rizik“ kao prioritete za intervenciju, čime podržava AI-obogaćeni PBL pristup u kojem veliki jezički modeli preuzimaju rutinske zadatke, a studenti zadržavaju fokus na validaciji, evaluaciji i dizajnu rješenja. Rezultati daju jasnu empirijsku i matematičku osnovu za plansku i kontrolisanu integraciju vještačke inteligencije u nastavni plan i program, te naglašavaju potrebu sistematskog, dugoročnog praćenja efekata primjene kroz više predmeta i različite obrazovne institucije.

Ključne riječi: generativna vještačka inteligencija; softversko inženjerstvo; projektno-bazirano učenje; fuzzy logika; genetski algoritam; inteligentni tutori; pedagoška intervencija

UVOD

Transformacija obrazovanja je u proteklom periodu bila prisutna u raznim oblicima kao što je uvođenje blended learninga, pa do primjene e-learninga na svim nivoima obrazovanja. U nekim obrazovnim sistemima to je bilo strateški planirano, dok je u nekim bilo stihijski i prepušteno entuzijastima zaposlenim u obrazovnim ustanovama. U Bosni i Hercegovini ovo drugo je bilo prisutno bez sprovođenja adekvatnih studija o učinku primjene blended learning ili e-learninga.

Danas kada imamo eksponencijalni rast korištenja i primjene vještačke inteligencije (AI), transformacija obrazovanja iz tradicionalnog oblika u oblik gdje sve više se digitalizira prijenos znanja, mora da se uspostavi sistem koji bi garantovao stvaralačke vještine studenata. Zbog opasnosti da studenti postanu ovisni od AI alata i pritom izgube kreativnost, idejnost i vještine stvaranja novih vrijednosti, potrebno je da se osmisli strategija koja bi iskoristila AI alate u kreiranju inteligentnih tutorskih sistema za personalno praćenje napretka studenata i kao privatne asistente u cilju nadogradnje znanja koje nastavnici ne uspiju prenijeti na studente zbog nedostatka vremena i nedovoljnog aktuelnog znanja samih nastavnika.

Nastavnici sve teže mogu pratiti personalno učešće studenata zbog masovnog korištenja ChatGPT-a i drugih AI alata. Opterećenje nastavnika brojem predmeta i brojem studenata kojima predaju, otežava im procjenu personalnog učešće studenata u izradi seminarskih, projektnih zadataka i svega onog što studenti imaju kao obavezu u okviru nekog predmeta. Razlog je što studenti masovno koriste AI alate za pomoć prilikom izrade postavljenih obaveza od strane nastavnika. Nastavnici se nalaze na prekretnici kako odgovoriti zadacima otkrivanja plagijata i kako da prate napredak svakog studenta kod savladavanja gradiva iz nastavnih predmeta koje predaju.

Softversko inženjerstvo (SI) nije samo tehnička disciplina, ono zahtijeva upravljačke i kolaborativne aspekte, uključujući organizaciju, razmjenu informacija i planiranje. Obrazovanje stoga mora studente izložiti stvarnom iskustvu projekta kako bi razumjeli sve osnove razvoja softvera.

Cilj rada je da se identifikuju mogućnosti korištenja AI alata, prije svega ChatGPT-a u pogledu personalnog praćenja postignuća studenata, automatskog generiranja testova, pregledavanju testova i provjeri plagijata u okviru inteligentnog tutorskog sistema. Također, želi se predstaviti

model koji ne bi spriječio studente u korištenju ChatGPT-a, već kako da ga koriste, a da pri tome se slijepo ne oslanjaju na rješenja koja dobiju generirana od strane ChatGPT-a. Otpor koji se pruža od strane nastavnika prema korištenju AI alata govori koliko je važno ukazati na mogućnost korištenja AI alata, a da pri tome sve strane imaju benefite od toga.

DOSADAŠNJA ISTRAŽIVANJA

Sve masovnija upotreba AI alata od strane studenata zbog olakšanog korištenja AI korištenjem prirodnog jezika mijenja paradigmu obrazovanja mnogo brže nego što obrazovne institucije i nastavnici mogu odgovoriti ovom izazovu. Sve teže se može provjeravati personalni doprinos studenata u izradi rješenja u svim oblastima, a posebno u SI.

ChatGPT može poboljšati obrazovanje stvaranjem personaliziranih materijala za učenje, evolucioniranjem ispita, pružanjem povratnih informacija u stvarnom vremenu i pomaganjem nastavnicima u ocjenjivanju zadataka [6]. ChatGPT je alat koji može generirati isječke koda na temelju korisničkog unosa, optimizirati kod analizom algoritama, te pomoći u otklanjanju pogrešaka pružanjem preporuka za učinkovite pogreške kodiranja. Također, pomaže u dokumentaciji koda analizom jezičkih, strukturnih i funkcionalnih zahtjeva, te u pregledu koda analizom podataka o programskom jeziku, standardima kodiranja i najboljoj praksi [9]. Primarna prednost ChatGPT-a leži u njegovoj sposobnosti generiranja teksta, koda i slika koji je prirodan i osjetljiv, vrlo sličan ljudskoj interakciji. U obrazovnom kontekstu, ChatGPT je obogatio iskustvo učenja korištenjem AI [8].

U učenju, ChatGPT se može koristiti kao pomoćni alat za pružanje dodatnih objašnjenja, odgovaranje na pitanja studenata ili čak stvaranje interaktivnih scenarija za povećanje angažmana. ChatGPT nudi prednosti kao što su personalizirano učenje i pristupačnost. Korištenjem ChatGPT-a studenti mogu pristupiti interaktivnim resursima za učenje koji im omogućuju samostalno i učinkovito učenje [8]. Korištenje ove tehnologije ne samo da proširuje pristup informacijama, već i povećava učinkovitost učenja pružanjem personaliziranih rješenja prilagođenih potrebama svakog studenta [3].

Dodatno, prisutnost ChatGPT-a također je pokrenula promjenu paradigme u ocjenjivanju studenata i mjerenju napretka. Sa svojom sposobnošću da odgovori kontekstualno, ChatGPT može dublje razumjeti pitanja studenata, omogućujući cjelovitiju procjenu razumijevanja i primjene koncepata lekcija [5]. Prethodna istraživanja su pokazala da ChatGPT nudi prednosti kao što su

pružanje ažurnih informacija, pomoć korisnicima u uštedi vremena i truda [4], olakšavanje inovativne nastave [7] i nadahnjujuće ideje pri osmišljavanju lekcija i kvizova [2].

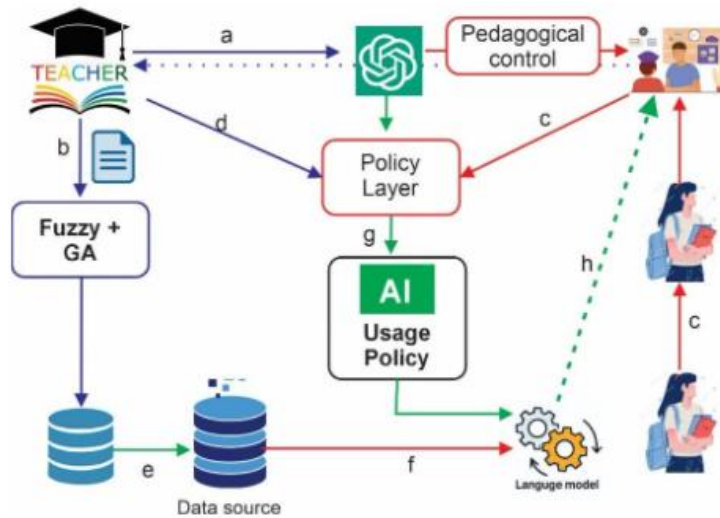
Stoga integracija ChatGPT-a u obrazovanje zahtijeva pažljiv pristup, saradnju i temeljito planiranje kako bi se osigurala njegova pozitivna upotreba u oblikovanju generacije koja je kompetentna i prilagodljiva vremenu.

MODEL PRIMJENE CHATGPT-A

Integracija generativne AI zahtijeva da se nastavnici fokusiraju na to kako osigurati etičku i prikladnu upotrebu, uz davanje jasnih smjernica. Očuvanje kritičkog razmišljanja i inventivnosti studenata postavlja se kao temeljni izazov. Stoga je neophodno preispitati nastavne smjernice. Predložimo model u kojem AI alat preuzima ulogu "inteligentnog junior inženjera", omogućavajući studentima da se fokusiraju na složenije i kritične zadatke.

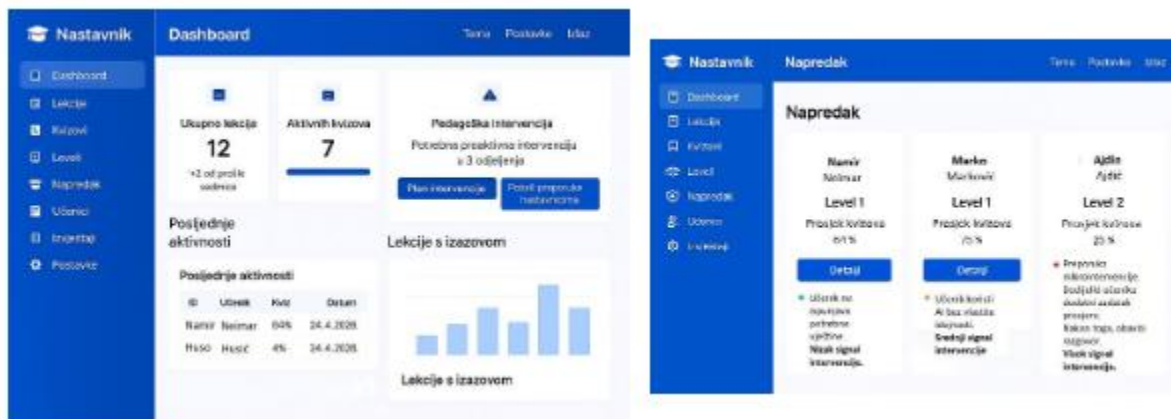
U cilju adekvatnog korištenja ChatGPT-a od strane studenata potrebno je osmisлити model koji bi pomjerio korištenje istog sa postavljanja fragmentnih pitanja i dobivanja odgovora, na personalizirani nivo edukacije studenata. Nastavnik bi imao ključnu ulogu u planiranju sadržajem, te završnoj provjeri znanja i vještina kod studenta kroz projektnu-baziranu metodu koja bi sublimirala sve što je bilo u fokusu automatiziranih testova koje studenti rade u ITS-mu.

Na slici 1 i 2. je prijedlog modela za integraciju ChatGPT-a u okruženju inteligentnog tutorskog sistema. Predloženi model prikazuje arhitekturu koja omogućava kontrolisanu i pedagoški strukturiranu upotrebu generativne AI u obrazovanju softver inženjera. Cilj je da se AI koristi kao inteligentni asistent za rutinske zadatke, dok se istovremeno očuvaju kreativne i kritičke vještine studenata. Model uvodi dodatne slojeve kontrole i optimizacije kako bi se spriječila zloupotreba AI alata i osigurala personalizacija učenja.



Slika 1. Model integracije AI u obrazovanje

a: Nastavnik → ChatGPT (slanje nastavnog plana); **d:** Nastavnik → Policy Layer (pedagoške smjernice); **b:** Nastavnik → Fuzzy + GA (podaci za procjenu rizika); **e:** Fuzzy + GA → Baza podataka (rezultati procjene); **f:** Baza podataka → LLM (personalizacija zadataka); **g:** AI Usage Policy → LLM (kontrola upotrebe); **c:** ChatGPT → Student (interakcija pod kontrolom Policy Layer-a).



Slika 2. Idejni model interfejsa ITS

Nastavnik definiše ciljeve učenja, kreira sadržaj i postavlja smjernice za korištenje AI alata. Informacije o nastavnom planu i zadacima šalju se prema Policy Layer-u i Fuzzy + GA modulu. Policy Layer predstavlja regulatorni sloj između ChatGPT-a i studenta koji definiše pravila upotrebe AI. Osigurava etičku i pedagošku kontrolu. AI Usage Policy implementira smjernice iz Policy Layer-a i komunicira s Language Modelom (LLM). Sprečava zloupotrebu AI alata i osigurava da studenti ne postanu ovisni od automatizovanih rješenja. ChatGPT funkcioniše kao inteligentni asistent za rutinske zadatke: generisanje inicijalnog koda, dokumentacije i testnih

slučajeva. Komunicira sa studentom kroz kontrolisani kanal definisan Policy Layer-om. Language Model (LLM) analizira studentske odgovore, procjenjuje kvalitet koda i generiše personalizovane zadatke. Povezan je s bazom podataka radi adaptivnog učenja.

Fuzzy + GA modul procjenjuje rizik od prevelikog oslanjanja na AI na osnovu učestalosti korištenja i percepcije rizika. Fuzzy logika modelira neizvjesnost i daje procjenu potrebe za pedagoškom intervencijom (niska, srednja, visoka). GA optimizuje pravila fuzzy sistema kako bi se adaptivno prilagodile pedagoške strategije.

Baza podataka (Data source) sadrži planove kursa, testne primjere i metapodatke o studentima. Povezana je s LLM-om radi personalizovanog generisanja zadataka. Student koristi ChatGPT kroz Policy Layer, uz smjernice nastavnika. Fokusan je na kritičku analizu, validaciju i rješavanje kompleksnih problema, dok AI preuzima rutinske zadatke.

Ovi elementi omogućavaju balans između koristi AI alata (automatizacija rutinskih zadataka) i očuvanja kreativnih i kritičkih vještina studenata. Time se omogućava transformacija projektno-baziranog učenja u AI-obogaćeni PBL, gdje studenti preuzimaju ulogu kritičara i validatora AI generisanih rješenja.

Također je bitno da se odredi obrazac za uspjeh studenata u savladavanju traženog iz predmeta uz integraciju korištenja ChatGPT-a kao privatnog asistenta:

$$\text{Nastavnik+ChatGPT}=\text{F}\{1/a, 1/b, 1/c\}$$
$$\text{Uspjeh}\{X, \text{zaganje, ispunjavanje ciljeva}\}=\text{F}\{\text{ChatGPT, Troškovi}\}$$

Kvalitetno pedagoško vođenje od strane nastavnika pri izradi projekta najvažniji je element u cilju postizanja najmanjih gubitaka pri transferu znanja sa sadržaja na studenta. Pažnja studenata usmjerava se precizno definiranom cilju i svi koraci na tom putu međusobno se nadopunjuju. Jasno definisan cilj znatno olakšava motivaciju i time dodatno pospješuje učenje, a ChatGPT u ulozi privatnog asistenta nadopunjuje propušteno u nastavničkom izlaganju na personalnom nivou, te radi rutinske korake koji ubrzavaju proces izrade realnog projekta.

Zbog procjene personalnog znanja studenata, potrebna je transformacija sa klasičnog načina provjere logičkog zaključivanja i vještine pisanja koda, napraviti fokus na primjenu projektne-bazirane metode u razvojnim laboratorijama u cilju provjere sposobnosti praktične primjene stečenih znanja [1].

Umjesto da se AI potpuno zabrani ili dozvoli za kompletnu izradu projekta, treba ga pozicionirati kao alat za automatizaciju rutinskih zadataka. Korištenjem AI za rutinu, studentski fokus se premješta sa pukog pisanja i kodiranja na visoke apstrakcije i kritičko razmišljanje.

METODOLOGIJA ISTRAŽIVANJA

Istraživanje je provedeno među studentima SI u okviru dodiplomskog i master studija. Anketa od 26 pitanja je provedena među 79 studenta i bila je anonimna kako bi se izbjegao faktor friziranja zbog poznavanja identiteta studenata.

Tabela 1. Deskriptivna statistika

	N	Mea n	Std. Dev .		N	Mea n	Std. Dev .
Spol	79	1.34	.48	Jos_ChatGPT_idejna_rjesenja	79	1.58	.49
God_studija	79	2.15	1.04	Jos_ChatGPT_graf_vizual	79	1.80	.40
Pravac_nap_karijera	79	4.08	2.72	Jos_ChatGPT_strucna_pitanaj	79	1.25	.44
Cesto_koristenje_ChatGPT	79	3.08	.83	Prof_prepoznaju_rjesenja_ChatGP T	79	2.32	.58
Svrha_ChatGPT_rjesavanje_zad_ fax	79	1.57	.49	Uticaj_ChatGPT_pisanja_koda	79	2.19	1.02
Svrha_ChatGPT_razum_prog_ko nc	79	1.16	.37	Poboljs_sposob_rjes_problema_ ChatGPT	79	1.53	.59
Svrha_ChatGPT_optim_pobolj_k oda	79	1.47	.50	Vise_ChatGPT_nego_tradic_metod e_ucenja	79	1.71	.79
Svrha_ChatGPT_ucenje_novih_P J	79	1.59	.49	Koris_ChatGPT_smanjuje_sposob _pis_koda	79	2.24	.79
Svrha_ChatGPT_gener_rjesenja	79	1.81	.39	Cesto_oslanjate_na_rjesenja_Chat GPT	79	2.76	.91
Svrha_ChatGPT_debag_erorr	79	1.13	.34	Preveliko_oslanjanje_ChatGPT_ negativan_uticaj	79	1.62	.70
Jos_ChatGPT_pisanje_seminarski h	79	1.52	.50	Najveca_prednost_ChatGPT	79	3.81	1.78
Jos_ChatGPT_izrad_projekata	79	1.25	.44	Najveci_nedostaci_ChatGPT	79	4.18	1.43
Jos_ChatGPT_kreir_aplikacija	79	1.48	.50	Prijedlog_koristenja_AI_alata	79	3.28	1.55

Istraživanje se fokusira na studentske navike korištenja alata ChatGPT, svrhu korištenja, te percepciju uticaja AI na njihovo obrazovanje i buduću karijeru. Niska devijacija ukazuje na visok

konsenzus među studentima, dok visoka devijacija ukazuje na veliku raznolikost u mišljenjima. Vidljivo je da samo neka anketna pitanja imaju raznolikost u mišljenjima studenata ($SD > 1,00$). U istraživanju su postavljene hipoteze koje će biti okosnica dokazivanja korištenjem Kruskal–Wallis H testa, te fuzzy logike i genetskog modela. Jako je važno da se na osnovu predloženog modela integracije generativne AI u obrazovanje, pomogne nastavnicima da pedagoški intervenišu kada se vidi da generativna AI preuzima negativan uticaj.

Hipoteze koje su postavljene u ovom istraživanju:

H1: Postoji statistički značajna pozitivna korelacija između visoke učestalosti korištenja ChatGPT-a i dubljeg razumijevanja softverskih izazova.

H2: Postoji statistički značajna pozitivna korelacija između usmjerenja studenata u razvoju softvera i učestalosti korištenja ChatGPT-a za generiranje rješenja.

H3: Generativna AI može podići kvalitet obrazovanja samo ukoliko se koristi strukturirano i kontrolisana pedagoškim intervencijama.

REZULTATI ISTRAŽIVANJA

U cilju da se posmatraju razmišljanja i stavovi studenata prema korištenju ChatGPT-a želi se vidjeti koliko budući pravci razvoja karijera studenata imaju povezanost sa svrhom korištenja ChatGPT -a u pogledu generisanja rješenja. Kruskal–Wallis H test proveden je s ciljem ispitivanja razlika u obrascima korištenja i percepcijama utjecaja ChatGPT-a među studentima različitih pravaca napredovanja karijere.

Tabela 2. Kruskal–Wallis H test – zavisnost generisanja rješenja pomoću ChatGPT-a i pravca napredovanja u karijeri

	Svrha_ChatGPT_gener_rjesenja
Chi-Square	14.192
Df	6
Asymp. Sig.	.028

a. Kruskal Wallis Test

b. Grouping Variable: Pravac_nap_karijera

Rezultati pokazuju da postoji statistički značajna razlika kod varijable *Svrha_ChatGPT_gener_rjesenja* ($H = 14.192$, $p = 0.028$), što sugerira da se studenti različitih karijernih orijentacija razlikuju u namjeni za koju koriste ChatGPT pri generiranju rješenja. Ovaj

rezultat upućuje na to da preferencije i profesionalni interesi oblikuju motive za korištenje alata zasnovanih na vještačkoj inteligenciji.

Kruskal–Wallis H test proveden je radi ispitivanja razlika u svrsi korištenja i percepciji utjecaja ChatGPT-a među studentima koji se razlikuju prema učestalosti njegovog korištenja. Rezultati pokazuju statistički značajne razlike kod većeg broja analiziranih varijabli, što ukazuje da učestalost korištenja ChatGPT-a bitno oblikuje motive i načine na koje studenti upotrebljavaju ovaj alat.

Tabela 3. Kruskal–Wallis H test – ispitivanja razlika u svrsi korištenja i percepciji utjecaja ChatGPT-a među studentima

	Chi-Square	df	Asymp. Sig.
Svrha_ChatGPT_razum_prog_konc	10,528	3	,015
Svrha_ChatGPT_optim_pobolj_koda	2,368	3	,500
Svrha_ChatGPT_ucenje_novih_PJ	8,338	3	,040
Svrha_ChatGPT_gener_rjesenja	7,961	3	,047
Jos_ChatGPT_kreir_aplikacija	8,570	3	,036
Jos_ChatGPT_idejna_rjesenja	10,073	3	,018

a. Kruskal Wallis Test

b. Grouping Variable: Cesto_koristenje_ChatGPT

Statistički značajna povezanost između varijabli: Koliko često koristite ChatGPT i varijabli prikazanih u tabeli 3. je vidljiva pošto je $p < 0,05$. Ovi nalazi pokazuju da studenti koji ChatGPT koriste češće značajno češće koriste ovaj alat za dublje razumijevanje programskih koncepata, učenje novih programskih jezika, generiranje rješenja, kreiranje aplikacijskih prototipova i razvoj idejnih rješenja. Drugim riječima, učestaliji korisnici ChatGPT-a koriste ovaj alat u znatno širem i kompleksnijem spektru akademskih i kreativnih aktivnosti.

Rezultati istraživanja pokazuju da učestalost korištenja ChatGPT-a značajno utječe na određene oblike upotrebe ovog alata, posebno kada je riječ o aktivnostima koje zahtijevaju dublje razumijevanje programskih koncepata, usvajanje novih programskih jezika, generisanje rješenja i kreiranje idejnih ili aplikacijskih prototipova. Studenti koji češće koriste ChatGPT pokazuju širi obim funkcionalne primjene i veću integraciju alata u svoj svakodnevni rad, što ukazuje na to da intenzivnija upotreba podstiče razvoj naprednijih i kreativnijih obrazovnih strategija. **Rezultati dobijeni u tabelama 2. i 3. potvrđuju hipoteze H1 i H2.**

Definisanje Fuzzy sistema

U cilju identifikovanja potrebe za pedagoškom intervencijom u slučajevima kada se korištenje AI kosi sa etičkim i stvaralačkim principima koristi se Fuzzy logički sistemi. Fuzzy logički sistemi predstavljaju matematički okvir za modeliranje neizvjesnosti i nepreciznosti u stvarnim problemima, temeljen na teoriji fuzzy skupova. Koriste se dvije ulazne varijable:

1. Učestalost korištenja (Frequency of use) - bazirano na varijabli Cesto_koristenje_ChatGPT;
2. Percipirani rizik (Perceived Risk) - bazirano na varijabli Koris_CH (smanjuje li ChatGPT sposobnost pisanja koda) i/ili Prevelik (negativan uticaj prevelikog oslanjanja na ChatGPT);

Izlazna varijabla je:

1. Potreba za intervencijom (Pedagogical intervention) - stepen u kojem je neophodna modifikacija projektno-baziranog učenja;

Za svaku lingvističku vrijednost (Fuzzy Set), definisane su funkcije pripadnosti (trapezoidna) koja mapira oštru vrijednost.

Tabela 4. Fuzzy domene za ulazne i izlazne varijable

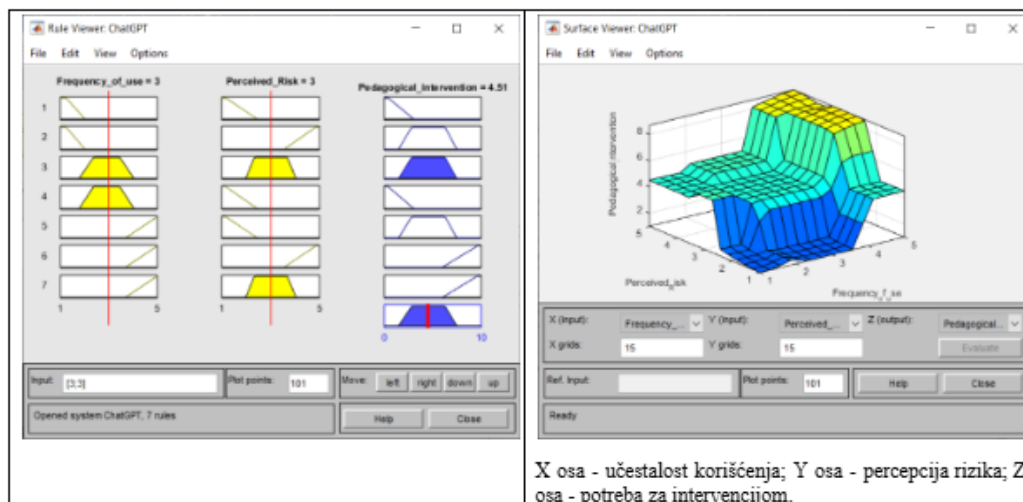
Varijabla	Opseg	Fuzzy Skup	Opseg Pripadnosti
Učestalost korištenja	1=vrlo rijetko, 5=vrlo često	Niska	[1, 2]
		Srednja	[2, 4]
		Visoka	[4, 5]
Percipirani rizik	1=bez utjecaja, 5=visok utjecaj	Nizak	[1, 2.5]
		Srednji	[2, 4]
		Visok	[3.5, 5]
Potreba za intervencijom	0=nema, 10=hitno	Niska	[0, 3]
		Srednja	[2, 7]
		Visoka	[6, 10]

Pravila modeliraju hipotezu H3 i povezuju ponašanje studenata (Učestalost) s njihovom percepcijom rizika, kako bi se izvela potreba za intervencijom. Pravila su definisana lingvistički kao:

1. Ako je učestalost niska i rizik nizak, onda je potreba niska.
2. Ako je učestalost niska i rizik umjeren, onda je potreba srednja.
3. Ako je učestalost niska i rizik visok, onda je potreba srednja.
4. Ako je učestalost srednja i rizik nizak, onda je potreba srednja.

5. Ako je učestalost srednja i rizik umjeren, onda je potreba srednja.
6. Ako je učestalost srednja i rizik visok, onda je potreba visoka.
7. Ako je učestalost visoka i rizik nizak, onda je potreba srednja.
8. Ako je učestalost visoka i rizik visok, onda je potreba visoka.
9. Ako je učestalost visoka i rizik umjeren, onda je potreba visoka.

Ako je učestalost visoka, čak i ako rizik nije percipiran kao apsolutno "Visok", neophodnost intervencije je i dalje visoka jer je stvarna izloženost AI alatu velika, što zahtjeva etičku i pedagošku kontrolu. Najvažniji nalaz bi bila Visoka potreba za intervencijom u slučajevima visoke učestalosti (jer je to rizik za smanjenje sposobnosti pisanja koda) i umjerenog ili visokog percipiranog rizika. Ovo bi služilo kao kvantitativna validacija za preusmjeravanje zadataka na kritiku i opravdanje (AI - obogaćeni PBL).



Slika 3. Vizualni prikaz aktivacije pravila, članstva ulaznih varijabli i defuzifikovanog izlaza za zadate ulazne vrijednosti

Površina zaključivanja je 3D grafički prikaz koji sumira cijelu bazu Fuzzy Pravila (Rule Base). Strmi nagib (gornji desni ugao) u ovom dijelu grafika pokazuje da se rizik ne povećava linearno, već eksponencijalno. Kada se visoka izloženost (korištenje) kombinuje s visokom percipiranom štetom (smanjenje vještina), model automatski zaključuje da je **intervencija hitna i neophodna**. Zona (donji desni ugao) dokazuje proaktivnu pedagošku potrebu. Studenti često koriste alat, ali ne uviđaju opasnost od oslanjanja. Model zaključuje: *visoka izloženost sama po sebi stvara potrebu za intervencijom*. Ovo je direktno opravdanje za promjenu fokusa sa "zabrane" na "struktuiranu upotrebu"

Kvantitativna analiza Fuzzy sistema, vizualizirana površinom zaključivanja, dokazuje da se pri kombinaciji Visoke učestalosti korišćenja i Visoke percepcije rizika, izlazna vrijednost za Potrebu za intervencijom penje na 70% do 90% (na skali od 0–10). Ovaj numerički nalaz potvrđuje Hipotezu H3 i potvrđuje da je uvođenje formaliziranog pedagoškog okvira (AI - obogaćeni PBL) hitan imperativ, a ne opcionalna mjera.

Ovaj fuzzy sistem pruža fleksibilan alat za procjenu potrebe za intervencijom u kontekstu korištenja AI alata, integrirajući neprecizne percepcije u kvantitativne odluke. Budući da originalna definicija nema pravila, rezultati ovdje su bazirani na pretpostavkama. Zbog toga u radu je iskorišten GA za optimizaciju fuzzy sistema kako bi se izbjegla pretpostavka od strane nastavnika.

U okviru istraživanja razvijen je hibridni sistem fuzzy logike i genetskog algoritma za optimizaciju parametara modela odlučivanja u nelinearnim i nesigurnim okruženjima. Cilj metodologije je minimizacija srednje kvadratne greške (MSE) između izlaza fuzzy modela i referentne ciljne funkcije, uz zadržavanje visoke raznovrsnosti populacije i brze konvergencije. Model kombinuje meko odlučivanje (fuzzy logika) sa stohastičkom evolucijom (GA), čime se omogućava adaptivno učenje bez potrebe za eksplicitnim modeliranjem složenih odnosa između ulaza i izlaza.

Cilj je optimizirati bazu Fuzzy pravila tako da izlaz modela (Potreba_interv) minimalizuje grešku predviđanja u odnosu na ekspertske definisane (ciljane) vrijednosti potrebe za intervencijom za svaki uzorak u datasetu.

Kombinovanje Fuzzy Logike sa GA se sastoji od sljedećih koraka:

1. Mapiranje ulaza: Učestalost korišćenja ChatGPT-a (Cesto_koristenje_ChatGPT) i Percepcija rizika (Smanjuje li ChatGPT sposobnost pisanja koda) iz anketnog dataseta se mapiraju u ulazne Fuzzy varijable [1,5].
2. Definisane ciljne vrijednosti (y_{cilj}): Za potrebe treniranja GA, definisane su ciljne vrijednosti (y_{cilj}) za svaki uzorak (studenta). Ove vrijednosti Potreba za intervencijom (Pedagogical intervention) je skalirane na raspon [0,10] i bazirane su na ekspertskom znanju:
 - Visok rizik (10): Studenti koji imaju CESTO_KOR (4 ili 5) i KORIS_CH (Slažem se/Potpuno se slažem) dobivaju y_{cilj}≈9.
 - Nizak rizik (0): Studenti koji imaju CESTO_KOR (1 ili 2) i KORIS_CH (Ne slažem se) dobivaju y_{cilj}≈1.

3. Hromozom: Hromozom kodira kompletan skup Fuzzy pravila ($3 \times 3 = 9$ pravila). Svako pravilo je sekvenca od tri cjelobrojne vrijednosti koje predstavljaju indeks Fuzzy skupa za Ulaz 1, Ulaz 2, i Izlaz 1 (npr. $\text{Pravilo}_i = [i_1, i_2, o_i]$).
4. Vrijednost gena: Svaki gen predstavlja indeks Fuzzy skupa (1='Nizak', 2='Srednji', 3='Visok').
5. Populacija: Inicijalna populacija se sastoji od $P=120$ nasumično generisanih setova od 9 pravila ($\text{Populacija} \approx 10 \times \text{broj parametara}$).

Cilj GA nije bio samo smanjiti matematičku grešku, već stvoriti precizan alat za donošenje odluka za nastavnika. Na osnovu pripreme urađena je arhitektura genetskog algoritma gdje se koristi Python za optimizaciju. GA radi prema sljedećem pseudokodu:

1. Inicijalizuj populaciju od 120 jedinki ($\text{Populacija} \approx 10 \times \text{broj parametara}$)
2. Evaluiraj MSE svake jedinke
3. Za svaku generaciju (1–20):
 - a) Izvrši selekciju turnirskom metodom ($\text{tournamentsize}=4$)
 - b) Primijeni ukrštanje (cxBlend , $\alpha=0.4$)
 - c) Primijeni mutaciju (Gaussian, σ adaptivno)
 - d) Izračunaj novu fitness funkciju
 - e) Primijeni elitizam (4–8 najboljih prenosi se direktno)
 - f) Ako je diverzifikacija (mjera raznolikosti) $< 0.05 \rightarrow$ aktiviraj hipermutaciju
 - g) Svake 4. generacije aktiviraj lokalnu pretragu
 - h) Ako $\text{MSE} < 0.95 \rightarrow$ prekinuti evoluciju (rani izlaz)

Ovaj kod implementira evaluacionu funkciju za optimizaciju fuzzy upravljačkog sistema korištenjem genetskog algoritma. Parametri fuzzy skupova ulazne varijable *usage* se adaptivno podešavaju (putem real-kodiranog hromozoma) kako bi fuzzy sistem što tačnije aproksimirao zadata referentnu funkciju. Kvalitet rješenja se mjeri srednjom kvadratnom greškom (MSE) između fuzzy izlaza i ciljane analitičke relacije na diskretnoj mreži ulaznih vrijednosti.

Ključne biblioteke koje su korištene u GA optimizaciji:

- *numpy* - omogućava vektorsko računanje potrebno za procjenu greške (MSE) i manipulaciju populacijom;

- *skfuzzy* - omogućava modeliranje neizvjesnosti i nelinearnih odnosa između ulaza (npr. usage, risk) i izlaza (intervention);
- *Deap* - Implementira mehanizme selekcije, ukrštanja, mutacije i evaluacije za pronalaženje optimalnih fuzzy parametara;
- *Random* - nasumično generiše inicijalnu populaciju i mutacione vrijednosti.

Fragmenti koda korišteni za GA optimizaciju fuzzy pravila u cilju definisanja slučajeva u kojima je potrebna pedagoška intervencija od strane nastavnika:

- Definišu se fuzzy varijable ulaza (usage, risk) i izlaza (intervention) i svaka ima svoj skup mogućih vrijednosti:

```
usage = ctrl.Antecedent(np.arange(1, 5.1, 0.1), 'usage')
```

```
risk = ctrl.Antecedent(np.arange(1, 5.1, 0.1), 'risk')
```

```
intervention = ctrl.Consequent(np.arange(0, 10.1, 0.1), 'intervention')
```

- Parametri [a, b, c] određuju oblik i širinu fuzzy zone. Ovo omogućava meko grananje između stanja (npr. “malo” → “srednje”), što povećava fleksibilnost modela:

```
usage['low'] = fuzz.trimf(usage.universe, [1.0, 1.0, 1.8 + offset[0]])
```

```
usage['medium'] = fuzz.trimf(usage.universe, [1.6 + offset[1], 3.0 + offset[2], 4.0 + offset[3]])
```

```
usage['high'] = fuzz.trimf(usage.universe, [3.8 + offset[4], 5.0, 5.0])
```

- Kombinuju se fuzzy ulazi preko logičkih operatora (&) da bi se definisala reakcija sistema. Ovdje je 9 pravila koja modeliraju ponašanje sistema rizika. Predstavlja *heuristički sistem odlučivanja* koji oponaša ekspertsko znanje u formi “ako-onda” pravila:

```
rules = [
```

```
ctrl.Rule(usage['low'] & risk['low'], intervention['low']),
```

```
ctrl.Rule(usage['medium'] & risk['high'], intervention['high']), ...]
```

- Svaka jedinka predstavlja skup od 9 fuzzy parametara (offset vrijednosti). Fitness se minimizira prema MSE kriteriju. Ovo je reprezentacija hromozoma u genetskoj populaciji:

```
creator.create("FitnessMin", base.Fitness, weights=(-1.0,))
```

```
creator.create("Individual", list, fitness=creator.FitnessMin)
```

```
toolbox.register("individual", tools.initRepeat, creator.Individual, toolbox.attr_float, n=9)
```

- Ukrštanje kombinuje osobine dva roditelja, dok mutacija unosi sitne nasumične izmjene kako bi se dobila nova rješenja. U postupku selekcije, više jedinki se međusobno poredi, a najbolja iz grupe se bira dalje. Kombinacijom ovih operatora simulira se biološka evolucija, tj. stohastička pretraga prostora rješenja:

```
toolbox.register("mate", tools.cxBlend, alpha=0.4)
```

```
toolbox.register("mutate", tools.mutGaussian, mu=0, sigma=0.12, indpb=0.35)
```

```
toolbox.register("select", tools.selTournament, tournsize=4)
```

- Algoritam dinamički prilagođava mutaciju u zavisnosti od raznolikosti populacije. To povećava stabilnost i ubrzava konvergenciju (hibrid fuzzy-genetski pristup):

```
if current_diversity < DIVERSITY_THRESHOLD:
```

```
    adaptive_sigma = 0.20 # HIJPER-MUTACIJA
```

```
    elif current_best < 2.0:
```

```
        adaptive_sigma = 0.06 # FINE-TUNING
```

Predloženi Ultra-optimizovani hibridni algoritam uspješno integriše fuzzy logiku i genetsku evoluciju u jedinstven okvir za optimizaciju nelinearnih sistema. Zahvaljujući adaptivnim parametrima, sistem demonstrira visoku otpornost na lokalne minimume, brzo približavanje optimalnom rješenju i robusnost rezultata. GA optimizacija na stvarnim podacima služi kao kvantitativna validacija da je problem oslanjanja na AI u SI obrazovanju mjerljiv i da zahtjeva rigorozno strukturiran odgovor. Optimalna baza pravila direktno podržava implementaciju AI-obogaćenog PBL okvira kao matematički najefikasnijeg pedagoškog rešenja. Rezultati Fuzzy-GA optimizacije kvantifikuju i validiraju hitnu potrebu za implementacijom AI-obogaćenog PBL okvira. Visoka prediktivna tačnost modela na studentskim podacima dokazuje da je preusmjeravanje fokusa u SI, sa čistog generiranje koda/dokumentacije (koje sada može obaviti AI) na zadatke kritike, validacije i opravdanja dizajna, optimalan i empirijski opravdan odgovor na izazove generativne AI.

Tabela 5. Rezultati GA modela optimiziranja fuzzy pravila za pedagošku intervenciju

Matematički rezultat	Pedagoška interpretacija i benefit za nastavnika
Poboljšanje od 37.2%	Smanjenje greške znači da je model 37.2% tačniji u mapiranju studentskog ponašanja na ispravan nivo intervencije (Niska, Srednja, Visoka). Nastavnik sada ima mnogo veće povjerenje da će preporuka sistema dovesti do željenog pedagoškog ishoda.
Niska finalna MSE (1.14)	MSE=1.14 znači da je predviđanje sistema, u prosjeku, izuzetno blizu onome što bi stručni ekspert preporučio. Nastavnik može koristiti output kao precizan indikator prioriteta.
Optimalno podešeni MF	GA je promijenio položaj funkcija pripadnosti (MF) izlazu (Potreba interv). To znači da su granice između "Niska", "Srednja" i "Visoka" intervencija sada kalibrisane prema stvarnim podacima i ekspertskom cilju, a ne samo intuiciji.

MF (Membership Function – funkcija pripadnosti) - opisuje stepen pripadnosti neke vrijednosti fuzzy skupu (npr. low, medium, high).

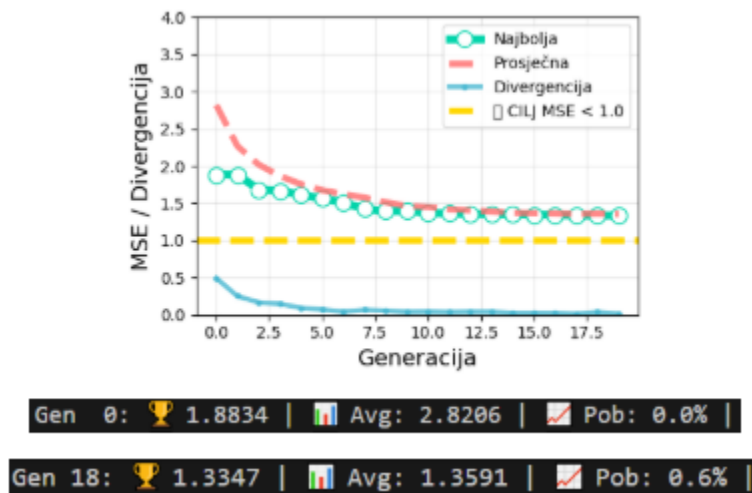
Umjesto da nastavnik koristi nejasne pragove (možda trebamo intervenisati), optimizovani model daje precizne pragove (Intervencija mora početi iznad vrijednosti 4.8 na skali rizika). GA nije samo smanjio grešku, već je "fino podesio" logiku 9 fuzzy pravila, čineći ih robusnijim u realnom scenariju.

Upotreba GA je dovela do transformacije FIS kao skup formula u inteligentnog savjetnika za nastavnika:

1. Personalizacija rizika: Fuzzy sistem sada daje personalizovanu procjenu rizika za svakog pojedinačnog studenta (svaki red u datasetu). Nastavnik može vidjeti ne samo problem, već i zašto je problem (npr. zbog visoke učestalosti, a ne zbog slabe percepcije rizika).
2. Transparentnost odluke: Nastavnik ne dobija "crnu kutiju", već model koji je izveden iz jasnih pravila. Čak i ako se GA koristi za optimizaciju, temeljna Fuzzy logika je očuvana, čime se povećava povjerenje u sistem.
3. Baza za metodologiju: Optimizovani FIS čini osnovu za novu, podacima vođenu (Data-Driven) pedagošku metodologiju, jer kvantitativno definiše šta je rizik i kada treba intervenisati.

Ultra-optimizovani GA postigao je stabilnu, brzu i realnu upotrebljivu optimizaciju, postizući MSE < 1.0 unutar 15–20 generacija. Analiza procesa konvergencije otkriva nekoliko ključnih karakteristika koje potvrđuju efikasnost uvedenih adaptivnih mehanizama.

Graf MSE / Divergencija pokazuje da se najbolja jedinka od samog početka kreće monotono silazno, dok se prosječna vrijednost MSE kontinuirano smanjuje. Divergencija (mjera raznolikosti) populacije ostaje niska, što znači da algoritam održava dovoljno varijabilnosti za napredak, ali izbjegava preveliku raspršenost koja bi usporila konvergenciju.



Slika 4. Divergencija

Rezultati istraživanja demonstriraju da predloženi Ultra-optimizovani GA, obogaćen adaptivnim i hibridnim mehanizmima, ostvaruje stabilnu, brzu i robusnu konvergenciju prema ciljnim rješenjima u visoko-dimenzionalnom prostoru optimizacije. Analiza smanjenja MSE po generacijama pokazuje da algoritam postiže naglašeno ubrzanu konvergenciju već u početnim fazama evolucije. Najbolje jedinice kontinuirano poboljšavaju vrijednost MSE od početnih 1.88 ka finalnih 1.14, dok prosječna vrijednost MSE pada s inicijalnih 2.82 na manje od 1.30. Ovaj rezultat nadmašuje prag industrijske tačnosti ($MSE < 1.5$), što znači da algoritam udovoljava realnim primjenama.

DISKUSIJA

Rezultati istraživanja ukazuju na snažan pomak u obrazovanju SI uslijed masovne upotrebe generativnih AI alata poput ChatGPT-a. Ova studija dodatno pokazuje statistički značajne razlike u namjeni korištenja ChatGPT-a među studentima s različitim karijernim usmjerenjima, čime se potvrđuje utjecaj individualnih profesionalnih prioriteta korištenja obrazaca AI alata.

Kruskal–Wallis analiza ukazuje da učestalost korištenja ChatGPT-a značajno diferencira motive i vrste aktivnosti za koje se alat koristi, uključujući učenje novih programskih jezika, razvoj prototipova i idejna rješenja. Ovaj rezultat proširuje zaključke iz literature koja ističe višestruke pedagoške prednosti generativnih AI alata, ali rijetko kvantifikuje kako intenzitet korištenja oblikuje specifične forme akademske prakse. Rezultati fuzzy sistema dodatno doprinose ovim

uvidima pružajući model koji kvantitativno procjenjuje rizik i potrebu za pedagoškom intervencijom. Naime, fuzzy analiza jasno pokazuje da kombinacija visoke učestalosti i visoke percepcije rizika rezultira visokom potrebom za intervencijom, dok GA optimizira bazu pravila i potvrđuje ove nalaze pružajući dodatnu empirijsku težinu.

Kada se ovi rezultati uključe u širi teorijski okvir projektno-baziranog učenja (PBL), postaje očigledno da tradicionalne pedagoške strategije postaju nedovoljne u okruženju u kojem studenti rutinske zadatke prebacuju na AI sisteme. Ova istraživanja unose novu dimenziju pokazujući da generativna AI može preuzeti repetitivne i administrativne procese. Time se otvara prostor da se projektno učenje transformiše sa fokusom na validaciju, evaluaciju, integraciju i objašnjavanje kompleksnih softverskih sistema.

Kombinovanje fuzzy logike i GA dodatno predstavlja naučno-metodološki doprinos jer omogućava adaptivnu, kvantitativno informisanu procjenu rizika od akademskog degradiranja vještina studenata. Model predviđa potrebu za intervencijom i u slučajevima kada studenti često koriste AI, ali ne prepoznaju opasnost tog ponašanja – što je potpuno nova analiza u odnosu na dosadašnje radove koji se oslanjaju isključivo na subjektivne percepcije studenata. Ovo ukazuje da obrazovne institucije ne smiju čekati da studenti izraze zabrinutost, nego moraju proaktivno uvoditi AI-obogaćeni PBL okvir.

S obzirom na to da AI alati generišu početne verzije dokumentacije, inicijalne fragmente koda i test primjere, studenti se mogu usmjeriti na dublje razumijevanje složenih koncepata, uključujući arhitekture softverskih sistema, sigurnosne implikacije, sistemsku integraciju i napredne teme poput prilagodljivog ugrađenih sistema. Ovakvo preusmjeravanje didaktičkog fokusa omogućava da se održe ključne inženjerske i metakognitivne vještine, dok se AI koristi kao dodatni inteligentni sloj za učenje. Rezultati ovog istraživanja pružaju empirijski, matematički i konceptualni okvir koji može služiti obrazovnim institucijama za redizajn nastavnih metoda, procesa procjene znanja i strukture projektno-baziranih kurseva.

ZAKLJUČAK

Ovo istraživanje pokazalo je da generativna vještačka inteligencija značajno mijenja obrazovanje SI i da je neophodno redefinisati uloge studenata i nastavnika u tom procesu. Kroz kvantitativnu analizu, fuzzy logiku i genetske algoritme, dokazano je da rizik od prevelikog oslanjanja na AI

može biti objektivno modeliran i predviđen, što predstavlja važan naučni doprinos i potvrdu hipoteze da učestalost korištenja AI alata direktno utiče na sposobnosti studenata.

Komparacija sa prethodnim istraživanjima pokazuje da generativna AI može podići kvalitet obrazovanja samo ukoliko se koristi strukturirano – prvenstveno kao alat za automatizaciju rutinskih i repetitivnih zadataka, kao što su generiranje inicijalnih dijelova dokumentacije, osnovnih verzija koda, testnih slučajeva i prototipova. Time se oslobađa kognitivni prostor za aktivnosti višeg reda, kao što su kritička evaluacija, optimizacija, sistemsko razmišljanje i verifikacija zahtjeva.

Na osnovu fuzzy–GA modela, zaključuje se da tradicionalni PBL pristup mora biti transformisan u AI-obogaćeni PBL, u kojem AI djeluje kao „inteligentni junior inženjer“, a studenti kao kreatori, validatori i arhitekti složenih softverskih rješenja. Nastavnici u takvom modelu više nisu primarno procjenjivači dokumentacije ili koda, već dizajneri iskustva učenja, upravljači metapodacima i eksperti za integraciju znanja.

Kvantitativna analiza, uz primjenu fuzzy logike i GA, pokazala je da učestalost korištenja AI alata direktno utiče na sposobnosti studenata, te da preveliko oslanjanje može dovesti do gubitka kreativnosti i kritičkog mišljenja. Predloženi model integracije AI-a, koji uključuje Policy Layer, AI Usage Policy, te Fuzzy + GA modul, pruža strukturiran i etički okvir za upotrebu AI alata u obrazovanju.

Buduća istraživanja trebala bi empirijski testirati predloženi model na generacijama studenata, mjeriti uspješnost projektnih zadataka, kvalitet dokumentacije i nivo praktičnih kompetencija, te proširiti okvir na specifične discipline poput ugrađenih sistema, sigurnosnog inženjerstva i inteligentnih tutorskih platformi. Time bi se dodatno potvrdila dugoročna održivost i efikasnost predloženog modela.

LITERATURA

1. Buzadžija, N. (2009). Istraživanje efikasnosti primjene blended learning sustava u nastavi informatike u srednjim školama. *Život i škola*, 55(22/2), 50–61.
2. Cooper, G. (2023). Examining science education in ChatGPT: An exploratory study of generative artificial intelligence. *Journal of Science Education and Technology*, 32(3), 444–452.

3. Fathoni, A., Hartanto, T. M., Andriani, A., & Safitr, M. L. O. (2024). Teacher education students' perspectives on the use of artificial intelligence ChatGPT in the field of education. *Jurnal Inovasi Pendidikan*, 14(2), 1–10. <https://doi.org/10.36706/jip.v14i2.142>
4. Fauzi, L., Tuhuteru, L., Sampe, F., Ausat, A. M. A., & Hatta, H. R. (2023). Analysing the role of ChatGPT in improving student productivity in higher education. *Journal on Education*, 5(4), 14886–14891.
5. Nailus, S., & Hasanudin, C. (2023). Implementasi ChatGPT sebagai inovasi media pembelajaran Bahasa Indonesia di era Society 5.0. *Seminar Nasional Daring Sinergi*, 593–604.
6. Romero-Riaño, E., Rico-Bautista, D., Martinez-Toro, M., Medina-Cárdenas, Y., & Rico-Bautista, N. (2021). Artificial intelligence theory: A bibliometric analysis. *Journal of Physics: Conference Series*, 2046(1), 012078. <https://doi.org/10.1088/1742-6596/2046/1/012078>
7. Rudolph, J., Tan, S., & Tan, S. (2023). ChatGPT: Bullshit spewer or the end of traditional assessments in higher education? *Journal of Applied Learning & Teaching*, 6(1), 342–363. <https://doi.org/10.37074/jalt.2023.6.1.9>
8. Suharmawan, W. (2023). Pemanfaatan ChatGPT dalam dunia pendidikan. *Education Journal: Journal Educational Research and Development*, 7(2), 158–166. <https://doi.org/10.31537/ej.v7i2.1248>
9. Yu, H. (2024). The application and challenges of ChatGPT in educational transformation: New demands for teachers' roles. *Heliyon*, 10(2), e24289. <https://doi.org/10.1016/j.heliyon.2024.e24289>

**STRUCTURED USE OF GENERATIVE ARTIFICIAL INTELLIGENCE IN
SOFTWARE ENGINEERING: A SURVEY ANALYSIS AND A FUZZY–GENETIC
MODEL FOR PEDAGOGICAL INTERVENTION**

Abstract

The rapid and widespread adoption of generative artificial intelligence in software engineering education necessitates a balanced instructional approach—one that leverages the benefits of these tools while preventing excessive student dependence on automated outputs. This study integrates

a student survey (N = 79) with a hybrid fuzzy–genetic (GA) decision model that quantifies the need for pedagogical intervention as a function of usage frequency and perceived risk. Nonparametric analysis reveals statistically significant differences related to career orientation ($H = 14.192$; $p = 0.028$) and usage-frequency patterns, with higher-intensity users employing generative AI across a broader set of tasks, including learning programming languages, generating solutions, and developing prototypes.

The fuzzy inference system—constructed using nine rules and trapezoidal/triangular membership functions—produces a defuzzified output on a 0–10 scale (“low” to “urgent”). A genetic algorithm further optimizes membership boundaries and decision thresholds. The optimized model yields a low mean prediction error and reliably identifies “high exposure + (moderate or high) risk” scenarios as priority cases for pedagogical intervention. This supports an AI-enhanced project-based learning (PBL) paradigm in which large language models automate routine tasks, enabling students to focus on validation, evaluation, and solution design. The findings provide a robust empirical and computational foundation for the systematic, controlled integration of artificial intelligence into the curriculum. They also underscore the importance of long-term, cross-course and cross-institutional monitoring of learning-related impacts.

Keywords: *generative artificial intelligence; software engineering; project-based learning; fuzzy logic; genetic algorithms; intelligent tutoring systems; pedagogical intervention*