Primljen: 4.3.2026.
Prihvaćen: 7.5.2026.

Stručni rad
UDK: 37.016:53:004.8

Umjetna inteligencija kao podrška prilikom rješavanja numeričkih zadataka iz fizike

Artificial Intelligence as a Support Tool for Solving Numerical Physics Problems

Andrea Baković Dragojević
Strojarska i prometna škola, Varaždin
Email: andrea.bakovic2@skole.hr

Sažetak: *Generativni alati umjetne inteligencije sve se češće koriste kao pomoć pri rješavanju zadataka iz fizike. Budući da numerički zadaci predstavljaju jedan od najvećih izazova u nastavi fizike te značajno utječu na uspjeh učenika na pisanim provjerama i ispitu državne mature, cilj ovog rada bio je ispitati može li umjetna inteligencija pružiti podršku u procesu njihova rješavanja.*

U radu su analizirana rješenja triju zadataka otvorenog tipa s ljetnog roka državne mature iz Fizike školske godine 2024./2025. Korištena su četiri generativna AI alata: ChatGPT (GPT-4o), Claude (Claude Sonnet 4.6), Gemini (Gemini 2.0 Flash) i Grok (Grok 3), pri čemu su upiti oblikovani u tri razine složenosti (jednostavan, srednji i napredan) iz perspektive učenika srednje strukovne škole.

Rezultati pokazuju da AI alati u većini slučajeva točno rješavaju zadatke te u velikoj mjeri slijede metodološki pristup rješavanja kakav se zahtijeva na državnoj maturi. S povećanjem složenosti upita raste i opseg objašnjenja, uključujući teorijsku razradu i interpretaciju rezultata. Ipak, uočeni su i određeni nedostaci u obliku pogrešaka u računu, neprecizne terminologije i nedovoljno prilagođenih objašnjenja za učenike slabijeg predznanja.

Zaključno, umjetna inteligencija može biti vrijedan alat u uvježbavanju numeričkih zadataka iz fizike i pružiti podršku učenicima u razvoju proceduralnog znanja. Međutim, njezina učinkovitost ovisi o načinu postavljanja upita i razini učenikove motivacije. Zbog toga ostaje

važna uloga nastavnika u usmjeravanju učenika, razvijanju njihova kritičkog pristupa te vještina preciznog formuliranja upita i jasnog definiranja problema.

***Ključne riječi**: umjetna inteligencija, nastava fizike, numerički zadaci, rješavanje problema, postavljanje upita, državna matura*

***Abstract:** Generative artificial intelligence tools are increasingly being used as support in solving physics problems. Since numerical tasks represent one of the greatest challenges in physics education and significantly influence students' performance in written assessments and the national graduation exam, the aim of this study was to examine whether artificial intelligence can provide support to students in the process of solving numerical problems.*

The study analyzes solutions to three open-ended tasks from the Physics section of the national graduation exam (Matura) from the summer session of the 2024/2025 school year. Four generative AI tools were used: ChatGPT (GPT-4o), Claude (Claude Sonnet 4.6), Gemini (Gemini 2.0 Flash) and Grok (Grok 3), and prompts were designed at three levels of complexity (simple, intermediate, and advanced) from the perspective of vocational secondary school students.

The results show that AI tools generally solve the tasks correctly and largely follow the methodological approach required in the Matura exam. As prompt complexity increases, so does the scope of explanations, including theoretical elaboration and interpretation of results. However, certain limitations were observed, such as computational errors, imprecise terminology, and explanations that are not sufficiently adapted to students with weaker prior knowledge.

In conclusion, artificial intelligence can be a valuable tool for practicing numerical physics problems and for supporting students in developing procedural knowledge. However, its effectiveness depends on the way prompts are formulated and on the student's level of motivation. Therefore, the teacher's role remains essential in guiding students, fostering their critical approach, and developing precise prompting and problem-definition skills.

***Keywords**: artificial intelligence, physics education, numerical physics problems, problem solving, prompt formulation, national exam (Matura)*

1. Uvod

Moderni alati umjetne inteligencije (AI alati) omogućuju učeniku da u nekoliko sekundi dobije potpuno rješenje fizikalnih problema. Sve što učenik treba je kopirati tekst zadatka u neki od spomenutih alata. Međutim, na pisanim provjerama znanja i testovima državne mature učenici često pokazuju značajan gubitak samostalnosti u primjeni metodološkog procesa rješavanja zadataka. Donedavno su učenici do brzih rješenja zadataka koje su propustili samostalno riješiti za vježbu i zadaću dolazili prepisivanjem od razrednih kolega, ako to nije bilo moguće, zadatak nisu predali. U takvom okruženju nastavnici su mogli detektirati učenike koji rješavaju zadaće samostalno i one koje to ne rade. Također se, na temelju rezultata samostalnog rada, mogla dobiti povratna informacija u kolikoj je mjeri i koje ishode učenja učenik usvojio, odnosno treba li mu dodatna pomoć. Danas, prvenstveno zahvaljujući umjetnoj inteligenciji, većina učenika dolazi na nastavu s točno riješenim zadacima, čak i onim složenijim. Nastavniku je teže odrediti koji su ishodi usvojeni, a na čemu bi se trebalo dodatno raditi i pomoći učeniku za bolje razumijevanje fizikalnih problema. Često tek provjere znanja i matura pokažu stvarnu sliku usvojenih vještina i stečenih kompetencija. Posljedično imamo slučajeve u kojima učenici na satu i iz zadaća postižu dobre rezultate, ali na pisanim provjerama i maturi ne mogu reproducirati čitav metodološki proces.

Zbog toga se otvara pitanje može li umjetna inteligencija pružiti podršku učeniku u razumijevanju postupka rješavanja zadataka, a ne samo ponuditi gotovo rješenje.

U radu se analizira metodika rješavanja numeričkih zadataka iz fizike pomoću primjene umjetne inteligencije. Postavlja se pitanje može li umjetna inteligencija poslužiti kao priprema za polaganje školskih pisanih provjera iz fizike i ispita državne mature. Cilj je utvrditi razlikuju li se, i u kojoj se mjeri, postupci rješavanja koje generiraju AI alati od standardnog metodološkog pristupa. Zatim će se provjeriti što se dogodi kada učenici preciznije definiraju svoj upit.

Cilj ovog rada je ispitati u kojoj mjeri generativni alati umjetne inteligencije mogu pružiti podršku učenicima pri rješavanju numeričkih zadataka iz fizike. U skladu s time postavljaju se sljedeća istraživačka pitanja: U kojoj mjeri AI alati slijede metodološki pristup rješavanja zadataka iz fizike? Kako razina složenosti upita utječe na kvalitetu dobivenih objašnjenja? Postoje li razlike među AI alatima u točnosti i didaktičkoj vrijednosti odgovora?

2. Teorijski okvir

2.1.Metodika rješavanja zadataka iz fizike

Rješavanje zadataka iz fizike predstavlja važan segment nastavnog procesa jer omogućuje primjenu teorijskih znanja na konkretne problemske situacije te pridonosi razvoju analitičkog i logičkog mišljenja učenika. U metodici nastave fizike naglašava se potreba za strukturiranim pristupom rješavanju zadataka (Slika 1), pri čemu je naglasak na razumijevanju fizikalnih zakonitosti i odnosa među veličinama, a ne na mehaničkom uvrštavanju podataka u unaprijed poznate formule.

Prvi korak, odnosno polazište rješavanja zadatka je pažljivo čitanje i razumijevanje zadanog problema. U ovoj fazi potrebno je prepoznati fizikalnu situaciju te prepoznati i izdvojiti poznate veličine i jasno odrediti traženu veličinu. Takav pristup omogućuje sustavno sagledavanje problema i predstavlja temelj za daljnje rješavanje i analizu. Sljedeći korak je kvalitativna analiza zadatka, koja obično uključuje izradu skice i/ili dijagrama, čime se dodatno olakšava razumijevanje odnosa među veličinama.

U nastavku procesa odabiru se odgovarajući fizikalni zakoni i jednadžbe te se uspostavlja matematički model problema. Kako ističe Luciano Kuhar (2007), uspješno rješavanje zadataka temelji se upravo na povezivanju zadanih i traženih veličina u smisleni matematički model, a ne na reprodukciji gotovih formula. Nakon toga slijedi kvantitativni dio rješavanja, koji uključuje uvrštavanje podataka i provođenje izračuna, pri čemu se dodatna pažnja treba obratiti preračunavanju mjernih jedinica. Završna faza odnosi se na provjeru dobivenog rezultata, pri čemu se procjenjuje njegova fizička smislenost i ispravnost postupka.

Slika 1: Metodika rješavanja numeričkih zadataka

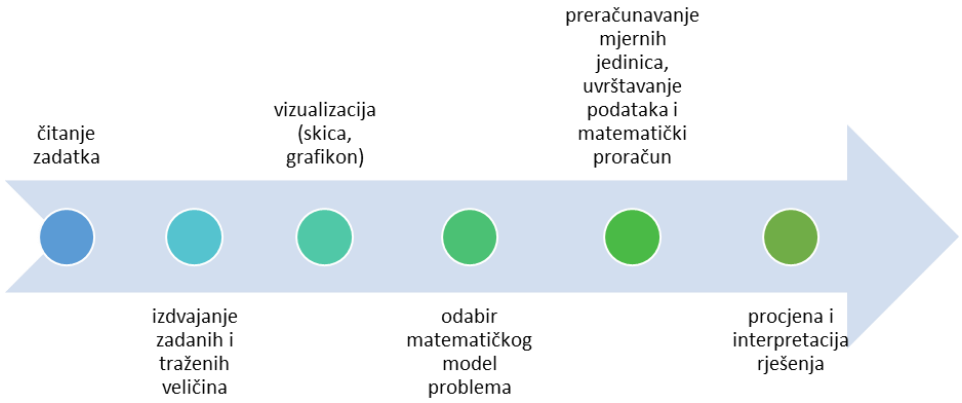

Izvor: autor

Prema Novosel (2017), pogreške koje se javljaju pri rješavanju fizikalnih zadataka često su posljedica nedovoljnog razumijevanja fizikalnih zakonitosti ili prisutnosti pretkoncepcija s kojima učenici pristupaju problemu. Osim toga, kao jedan od značajnih uzroka pogrešaka ističe se primjena gotovih formula i jednadžbi bez njihova stvarnog razumijevanja i bez sagledavanja konteksta u kojem se koriste.

Novosel također naglašava da učenici često preskaču pojedine korake u postupku rješavanja zadataka, osobito pri rješavanju i izvođenju jednadžbi, što može dovesti do netočnih rezultata. Dodatni problem predstavlja izostanak vizualizacije fizikalnog problema, odnosno nekorištenje skica i dijagrama, koji imaju važnu ulogu u razumijevanju odnosa među fizikalnim veličinama (Novosel, 2017).

Strukturirani pristup rješavanju zadataka usko je povezan s načelima edukacijskog konstruktivizma. Prema Rudolfu Krsniku (2008), znanje nije moguće prenijeti učeniku kao gotov proizvod, nego ono nastaje kao rezultat njegove vlastite aktivnosti i interpretacije. U tom kontekstu Krsnik ističe da učenik aktivno sudjeluje u procesu učenja, dok nastavnik ima ulogu usmjeravatelja koji potiče učenikovo promišljanje i razumijevanje.

Primjena konstruktivističkog pristupa posebno dolazi do izražaja upravo u rješavanju zadataka, gdje učenik kroz analizu problema, postavljanje modela i provjeru rješenja aktivno konstruira vlastito znanje. Nadalje, Krsnik (2008) ističe kako nastavnik ne treba promatrati sadržaj koji poučava kao konačnu istinu, nego kao jedan od mogućih načina interpretacije određene pojave, čime se potiče razvoj kritičkog mišljenja i dubljeg razumijevanja.

Suvremeni pristup poučavanju može se dodatno sagledati kroz rad Češi (2024) koja naglašava važnost aktivne uloge učenika i jasno strukturiranog nastavnog procesa. Autorica učenje definira kao djelovanje kojim se razvijaju sposobnosti te stječu znanja i vještine, dok aktivnost učenika opisuje kao proces ovladavanja sadržajima i vještinama učenja. S druge strane, aktivnost učitelja usmjerena je na poticanje učenikove aktivnosti i stvaranje uvjeta za učinkovito učenje (Češi, 2024).

U svom radu Češi (2024) poseban naglasak stavlja na jasno definiranje ciljeva nastavnog sata, pri čemu polazišno pitanje postaje što se očekuje da će učenik znati ili moći učiniti nakon poučavanja. Time se ističe važnost odgojno-obrazovnih ishoda kao temeljne sastavnice planiranja nastave. Ovakav pristup u skladu je s konstruktivističkim načelima jer usmjerava nastavni proces na učenikovu aktivnost i konkretne rezultate učenja, a ne samo na sadržaj koji se poučava.

Kada je riječ o motivaciji učenika, dodatno se naglašava uloga učitelja, čiji stav i odnos prema nastavnom sadržaju mogu značajno utjecati na interes učenika. Povezivanje nastavnog sadržaja s konkretnim i učenicima bliskim primjerima doprinosi većoj angažiranosti te potiče dublje razumijevanje gradiva (Češi, 2024). Takav pristup posebno je važan u nastavi fizike, gdje se apstraktni pojmovi često lakše usvajaju kroz primjenu na stvarne situacije.

Konstruktivistički pristup organizaciji kurikula podrazumijeva povezivanje različitih nastavnih sadržaja u smislene cjeline te primjenu načela „dubina ispred širine“. Takav pristup omogućuje detaljniju obradu manjih cjelina gradiva, čime se potiče kvalitetnije usvajanje znanja i njegova primjena u različitim situacijama (Krsnik, 2008).

Krsnik (2008) posebno naglašava razliku između činjeničnog i proceduralnog znanja. Dok činjenično znanje često ostaje na razini reprodukcije informacija, proceduralno znanje omogućuje primjenu naučenog u novim i nepoznatim situacijama. Upravo je razvoj proceduralnog znanja jedan od ključnih ciljeva nastave fizike, budući da ono učenicima omogućuje uspješnije rješavanje problemskih zadataka i prilagodbu izazovima suvremenog društva.

Može se istaknuti kako strukturirani postupak rješavanja zadataka, utemeljen na konstruktivističkim načelima i suvremenim didaktičkim pristupima, predstavlja učinkovit način razvoja razumijevanja fizikalnih zakonitosti. Takav pristup ne samo da omogućuje uspješnije rješavanje zadataka, nego i doprinosi razvoju sposobnosti primjene znanja u različitim kontekstima, što je jedan od temeljnih ciljeva suvremenog obrazovanja.

2.2. Umjetna inteligencija

U udžbeniku *Uvod u umjetnu inteligenciju* Stipaničev i suradnici (2021) ističu kako ne postoji jedinstvena i općeprihvaćena definicija umjetne inteligencije (engl. Artificial Intelligence). Ipak, kao jednu od prikladnijih navode definiciju Elaine Rich, prema kojoj je umjetna inteligencija znanstveno područje usmjereno na razvoj strojeva, odnosno računala, sposobnih obavljati zadatke koje u danom trenutku čovjek izvršava uspješnije (Rich, kako je navedeno u Stipaničev i sur., 2021).

Autori pritom izdvajaju dva temeljna motiva razvoja umjetne inteligencije. Prvi se odnosi na nastojanje da se bolje razumije ljudska, odnosno biološka inteligencija, dok je drugi usmjeren na zamjenu čovjeka u obavljanju zadataka koji su zamorni, monotoni, zahtjevni ili opasni. Ističe se kako je osnovni cilj umjetne inteligencije razvoj sustava koji se ponašaju na način usporediv

s ljudskim djelovanjem. Pritom se naglašava da nije presudan sam proces dolaska do rješenja, nego kvaliteta rezultata, odnosno da rješenje bude jednako dobro ili bolje od onoga koje bi postigao čovjek.

Jedno od važnih područja unutar umjetne inteligencije jest inženjerstvo znanja, koje se bavi načinima prikupljanja, prikazivanja, pohrane i manipulacije znanjem. Hayes-Roth i suradnici (1983) ističu različite mogućnosti primjene umjetne inteligencije, među kojima je za ovaj rad posebno značajna njezina primjena u obrazovanju. Kao jedna od ključnih kategorija navodi se podučavanje, koje uključuje prenošenje znanja i vještina, dijagnosticiranje razine usvojenosti znanja, prepoznavanje nedostataka te njihovo otklanjanje, primjerice putem inteligentnih tutorskih sustava.

S obzirom na sve širu primjenu umjetne inteligencije, posebna se pozornost posvećuje i etičkim aspektima njezina razvoja i primjene. Europska unija donijela je dokument *Etičke smjernice za pouzdanu umjetnu inteligenciju* (engl. *Ethics Guidelines for Trustworthy AI*), u kojem se ističe da pouzdana umjetna inteligencija treba biti zakonita, etična i otporna. Navedene sastavnice trebale bi djelovati usklađeno i međusobno se nadopunjavati kako bi se osigurala odgovorna i sigurna primjena umjetne inteligencije u društvu (Europska komisija, 2019).

2.3. Umjetna inteligencija i obrazovanje

U svom radu Komar (2025) postavlja pitanje može li umjetna inteligencija zamijeniti pedagoge i učitelje. Dolazi do zaključka da umjetna inteligencija nema karakter biti pedagogična, ali može poslužiti kao izvrstan alat u pomoćnim pedagoškim radnjama. Do sličnog zaključka dolaze Topolovčan i Vanek (2025) prema kojima umjetna inteligencija neće zamijeniti učitelja nego staviti naglasak na primjenu novih tehnologija u razvoju vještina i rješavanju problema.

Cerovac i Černeha (2025) ističu da digitalne tehnologije omogućuju prilagodbu nastavnog procesa na način da on poprimi gotovo individualizirani pristup za svakog učenika, ali upozoravaju i na moguće opasnosti koje sa sobom donose takve promjene u obrazovanju. Kao posebne rizike ističu: moguće smanjenje autonomije učenika, perpetuiranje društvenih normi, vrijednosti i predrasuda te gubitak nekih kognitivnih vještina.

Analize učinkovitosti primjene umjetne inteligencije u obrazovanju pokazuju njezin pozitivan utjecaj na nastavni proces. Istraživanje koje su proveli Chen i suradnici (2020) pokazuje da učitelji koji koriste umjetnu inteligenciju postižu veću učinkovitost te učenicima pružaju kvalitetnije iskustvo učenja (kako je navedeno u Mrnjaus i sur., 2023). U tom se okviru ističu

tri ključne funkcije umjetne inteligencije u obrazovanju: administracija, poučavanje i učenje. Administrativna funkcija obuhvaća aktivnosti poput ispravljanja radova, ocjenjivanja i davanja povratnih informacija, funkcija poučavanja se odnosi na izradu i prilagodbu nastavnih sadržaja, dok funkcija učenja uključuje praćenje napretka učenika, prepoznavanje poteškoća i prilagodbu učeničkim individualnim potrebama.

Mrnjaus i suradnici (2023) ističu kako umjetna inteligencija u radu s učenicima pokazuje visoku razinu prilagodljivosti i strpljenja, što može smanjiti strah od pogreške i potaknuti aktivnije sudjelovanje u učenju. Unatoč tome, autori naglašavaju da umjetna inteligencija neće u potpunosti zamijeniti učitelje jer oni u obrazovni proces unose emocionalnu, socijalnu i kulturnu dimenziju koja je nezamjenjiva.

Važnost etičkog i odgovornog korištenja umjetne inteligencije dodatno je naglašena u smjernicama Europske komisije koje se odnose na primjenu umjetne inteligencije u poučavanju i učenju. Smjernice ističu mogućnosti primjene prilagodljivih tehnologija učenja, automatiziranog ocjenjivanja, personaliziranih intervencija te uporabe digitalnih alata poput chatbotova u administrativnim i obrazovnim procesima, uz naglasak na razvoj kompetencija za etičku uporabu umjetne inteligencije (Europska komisija, kako je navedeno u Mrnjaus i sur., 2023).

Može se istaknuti kako umjetna inteligencija predstavlja značajan potencijal za unapređenje obrazovnog sustava, osobito u području personalizacije učenja i povećanja učinkovitosti nastavnog procesa. Ipak, njezina primjena zahtijeva pažljivo promišljanje kako bi se izbjegli mogući negativni učinci te očuvala ključna uloga učitelja kao nositelja odgojno-obrazovnog procesa.

2.4. Ispit iz fizike na državnoj maturi

Prema Ispitnom katalogu za državnu maturu u školskoj godini 2025./2026. u ispitu iz Fizike provjeravaju se četiri područja: Struktura tvari, Međudjelovanje, Gibanje i Energija. Ispit se sastoji od 35 zadataka. Zastupljenost potpodručja unutar spomenutih područja ispitivanja dana je u Tablici 1 (NCVVO, 2025a).

Tablica 1: Udjeli potpodručja ispitivanja

POTPODRUČJE ISPITIVANJA	UDIO BODOVA	ZADACI ZATVORENOG TIPA	ZADACI OTVORENOG TIPA
MEHANIKA	25%	5	3
TERMODINAMIKA	15%	4	2
ELEKTROMAGNETIZAM	25%	5	3
TITRANJE, VALOVI I OPTIKA	20%	5	2
MODERNA FIZIKA	15%	5	1
UKUPNO	100%	24	11

Izvor: NCVVO (2025a)

Prema katalogu u ispitu se pojavljuju zadaci zatvorenog i otvorenog tipa. Zadaci zatvorenog tipa nose 1 bod, a zadaci otvorenog tipa, ovisno o složenosti i razini kognitivnih procesa koju ispituju, mogu nositi 2, 3 ili 4 boda. Struktura ispita prikazana je Tablicom 2 i Slikom 2. (NCVVO, 2025a).

Tablica 2: Struktura ispita državne mature iz Fizike

STRUKTURA ISPITA DRŽAVNE MATURE IZ FIZIKE			
VRSTA ZADATAKA	**BROJA ZADATAKA**	**BROJ BODOVA**	**UDIO BODOVA U ISPITU**
zadaci zatvorenog tipa (višestrukog izbora)	24	24	40%
zadaci otvorenog tipa (produženog odgovora)	11	36	60%

Izvor: NCVVO (2025a)

Slika 2: Struktura ispita državne mature

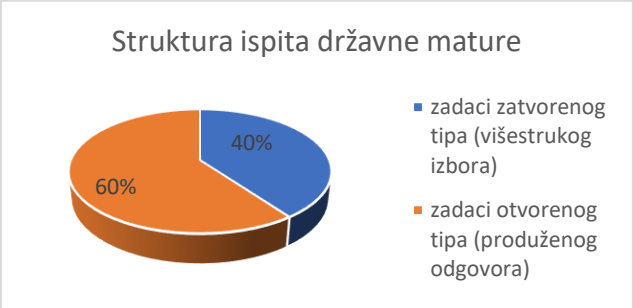

Izvor: NCVVO (2025a)

Nakon svakog ispitnog roka objavljuju se materijali vezani uz provedeni ispit među kojima se, osim samih zadataka, nalazi i detaljan postupak rješavanja i bodovanja svakog zadatka.

3. Metodologija

3.1. Dizajn istraživanja

Istraživanje je provedeno kao kvalitativna analiza odgovora generativnih AI alata na upite vezane uz zadatke iz fizike.

3.2. Uzorak zadataka

Za testiranje načina na koji umjetna inteligencija rješava zadatke i kako se koraci rješavanja mijenjaju s obzirom na kvalitetu upita, odabrana su tri zadatka otvorenog tipa koja su se pojavila na prvom ispitnom roku državne mature iz Fizike prošle godine (ljetni rok školske godine 2024./2025). Zadaci su odabrani jer su javno dostupni te je njihov način bodovanja s obzirom na korake rješavanja precizno i jasno opisan. Zadaci su dostupni na mrežnim stranicama Nacionalnog centra za vanjsko vrednovanje obrazovanja (NCVVO, 2025b). U radu se analiziraju odgovori dobiveni s obzirom na stupanj složenosti upita.

3.2.1. Prvi odabrani zadatak

Prvi zadatak rješavan pomoću umjetne inteligencije jest 32. zadatak s ljetnog ispitnog roka državne mature u školskoj godini 2024./2025. Zadatak je nosio 4 boda, što znači da spada u najsloženije zadatke jer ispituje četiri razine kognitivnih procesa: znanje, razumijevanje, primjenu i analizu. Budući da upute za pisanje ispita sadrže napomenu da se prilikom računanja ubrzanje slobodnog pada pri površini Zemlje zaokruži na 10 m/s^2, ta je rečenica dodana na kraj izvornog zadatka. Time se osiguralo da se dobiveno rješenje u potpunosti podudara sa službenim rješenjem koje se nalazi u Ključu za odgovore koji je objavio NCVVO.

Zadatak 32: Tijelo mase 15 mg i naboja $q_1 = 25$ nC nalazi se u homogenome električnom polju ovješeno na nit duljine ℓ. Električno polje iznosa 40 N/C usmjereno je vertikalno prema dolje. Na koju udaljenost ispod naboja q_1 treba postaviti točkasti naboj $q_2 = 10$ nC kako bi napetost niti iznosila $1{,}208 \cdot 10^{-4}$ N? Naboji su smješteni u zraku. Zanemarite uzgon u zraku i masu niti. Za g uzmite 10 m/s^2.

3.2.2. Drugi odabrani zadatak

Drugi odabrani zadatak bio je 28. na prošlogodišnjem ljetnom ispitnom roku državne mature iz Fizike. Zadatak je nešto jednostavniji od prethodnog i zahtijeva manje računskih koraka. Njegovim rješavanjem učenici su na maturi ostvarili tri boda, a ispituje tri razine kognitivnih procesa: znanje, razumijevanje i primjenu.

Zadatak 28: Protok vode kroz horizontalno postavljenu cijev iznosi 0,02 m^3/s. Površina poprečnoga presjeka jednoga dijela cijevi iznosi 50 cm^2. Koliko iznosi dinamički tlak u tome dijelu cijevi? Gustoća vode iznosi 1000 kg/m^3.

3.2.3. Treći odabrani zadatak

Treći, ujedno i zadnji, odabrani zadatak bio je 25. na prošlogodišnjem ljetnom ispitnom roku državne mature iz Fizike. Zadatak je jednostavniji i ne zahtijeva mnogo računskih koraka. Njegovim rješavanjem učenici su na maturi ostvarili dva boda, a zadatak ispituje dvije razine kognitivnih procesa: znanje i razumijevanje.

Zadatak 25: Carnotov toplinski stroj sastoji se od dvaju toplinskih spremnika, jedan temperature 400 K, a drugi temperature 300 K. Kolika je korisnost toga toplinskog stroja?

3.3. AI alati

Generativni alati, odnosno njihova korisnička sučelja korištena za provedbu ovog istraživanja su: ChatGPT (model koji ga pokreće jest GPT-4o), Claude (model Claude Sonnet 4.6), Gemini (model Gemini 2.0 Flash) i Grok (model Grok 3). Nazivi modela odnose se na besplatne verzije alata dostupne korisnicima u trenutku provedbe istraživanja. Svaki model razvijen je u skladu s drugačijim tehnološkim prioritetima te se razlikuju po svojim mogućnostima i pristupu analizi problemskih zadataka. Model GPT-4o karakterizira visoka svestranost i uravnoteženi pristup jezičnim, matematičkim i logičkim zadacima, zbog čega može poslužiti kao opći asistent (OpenAI, 2024). Claude Sonnet 4.6 ističe se naprednim sposobnostima proširenog razmišljanja, što poboljšava točnost pri rješavanju složenih matematičkih i logičkih problema (Anthropic, 2025). Gemini 2.0 Flash primarno je optimiziran za brzu obradu i multimodalni unos podataka, pri čemu se naglasak stavlja na brzo generiranje povratnih informacija (Google DeepMind, 2025). Grok 3 ističe se integracijom s podacima u realnom vremenu i naprednim sposobnostima logičkog zaključivanja (xAI, 2025).

Treba napomenuti da u besplatnim verzijama AI alata korisnici često nemaju uvid u točan model koji se koristi zato što sustav dinamički prilagođava model ovisno o opterećenju i dostupnosti. Zbog lakše čitljivosti u nastavku rada pisat će se nazivi alata, dok će se razvojna generacija modela izostaviti.

3.4. Tri razine upita

Upiti su razvrstani u tri kategorije: jednostavan upit, srednji upit i napredan upit. U nastavku teksta slijedi kratak opis svakog upita, a sažetak je dan u Tablici 3. Upiti korišteni u istraživanju

oblikovani su na temelju uočenih obrazaca pisanja koji imaju učenici srednje strukovne škole kada traže pomoć. Formulirani su iz perspektive učenika te odražavaju njihov jezik, razinu razumijevanja fizikalnih pojmova i uobičajeni način postavljanja problema.

Važno je naglasiti da se složenost upita promatra u kontekstu ciljane skupine. Ono što učenici ove strukovne škole percipiraju kao „složen“ upit, može se smatrati „jednostavnim“ za nastavnika, studenta prirodnih znanosti ili učenika s više iskustva u formuliranju upita i razvijenijim vještinama rješavanja problemskih zadataka.

Nesvjesni kako moćan alat imaju na raspolaganju učenici često umjetnu inteligenciju koriste na onaj najjednostavniji, najbrži i „najlošiji“ način - kao tražilicu. Zadatak samo kopiraju ili pretipkaju u odabrani AI alat i prepišu dobiveni rezultat. Takav način je u većini slučajeva dovoljan za brzo i učinkovito rješavanje zadaće ili nekog drugog zadatka dobivenog za samostalno rješavanje. Iz priloženih rezultata istraživanja u nastavku vidljivo je da umjetna inteligencija zbilja rijetko griješi prilikom rješavanja zadataka na razini srednje škole, a i opis postupka koji pri tome daje je sasvim zadovoljavajući za osobu upućenu u problematiku. Učenici koji redovito uče i vježbaju samostalno rješavanje zadataka u većini slučajeva shvatit će postupak rješavanja, ali takav način nije dovoljan za učenike kojima treba pomoć. Oni bi svoj upit trebali definirati preciznije te, prema potrebi, jasno naglasiti da im treba pomoć u razumijevanju postupka rješavanja. Zato je prvi upit u ovom radu postavljen upravo na taj najbrži i najjednostavniji način – izravnim kopiranjem zadatka, bez ikakvih dodatnih uputa.

Drugi stupanj složenosti upita označen je kao srednji, a razlikuje se od jednostavnog po tome što je prije teksta zadatka dodana rečenica koja glasi: „Potrebno je postupno i detaljno riješiti i objasniti fizikalni problem sljedećeg zadatka“. Ovim se upitom očekuje dobiti nešto detaljniji postupak rješavanja koji će biti opisno popraćen teorijskim objašnjenjima fizikalnog problema. Ne očekuje se detaljna analiza dobivenog rješenja niti njegova fizikalna interpretacija.

Kod naprednog upita ispred samog teksta zadatka dodano je: „Učenik sam 2. razreda srednje strukovne škole. Sljedeći zadatak treba riješiti postupno i detaljno te objasniti njegov fizikalni problem. Postupak treba sadržavati skice. Dobiveno rješenje treba analizirati i staviti u kontekst danog fizikalnog problema“. Upit postavljen na ovaj način osigurava da učenik dobije potpuno prilagođen metodološki pristup. Time se osigurava i vizualna perspektiva koja je često nužna za razumijevanje na koji način treba pristupiti rješavanju zadanog problema. Također, ponuđena su objašnjenja koja učenik može razumjeti jer su izrečena na njemu prihvatljivoj razini poznavanja fizike. Isto se odnosi na matematičku komponentu rješavanja zadataka u kojoj se

primjenjuje srednjoškolska razina znanja i vještina. Na kraju, uz samo rješenje trebala bi se nalaziti njegova fizikalna interpretacija te kritički osvrt, također u skladu s razinom znanja na kojoj se učenik koji postavlja upit nalazi ili bi se trebao nalaziti.

Tablica 3: Sažeti prikaz razina upita i očekivanih odgovora umjetne inteligencije

Razina upita	Opis upita	Očekivani AI odgovor
jednostavan	Tekst zadatka	Rješenje zadatka uz osnovni postupak.
srednji	Tekst zadatka + „postupno i detaljno riješiti i objasniti fizikalni problem sljedećeg zadatka“	Rješenje zadatka uz detaljni postupak i teorijska objašnjenja.
napredan	Tekst zadatka + „zadatak treba riješiti postupno i detaljno te objasniti njegov fizikalni problem. Postupak treba sadržavati skice. Dobiveno rješenje treba analizirati i staviti u kontekst danog fizikalnog problema“	Detaljan postupak rješavanja, skice i objašnjenja na razini SSŠ; interpretacija i analiza dobivenog rješenja.

Izvor: autor

3.5. Kriterij analize odgovora

Dobiveni AI odgovori analizirani su prema sljedećim kriterijima: točnost rješenja zadatka, usklađenost s metodološkim postupkom rješavanja, jasnoća i razina objašnjenja postupka rješavanja zadatka, terminološka točnost, prisutnost analize i interpretacije rezultata.

4. Rezultati

U nastavku se prikazuju rezultati dobiveni analizom odgovora AI alata za odabrane zadatke. Na kraju odlomka nalazi se Tablica 4 sa sažetim rezultatima. Cjeloviti upiti i dobiveni odgovori nalaze se u Dodatku.

4.1. Zadatak 32

a) Jednostavan upit

Svi AI alati zadatak su riješili točno, postupak rješavanja obuhvatio je sve korake predviđene rješenjima s državne mature. ChatGPT i Claude nisu analizirali dobiveno rješenje, dok su to Gemini i Grok napravili unatoč tome što se to u upitu nije eksplicitno tražilo. Što se tiče teorijskog objašnjenja zadataka, tu se Gemini pokazao najdetaljnijim, dok je Claude dao samo najosnovnije informacije. U nekim odgovorima uočena je neprecizna uporaba fizikalne terminologije, primjerice zamjena pojmova sile teže i težine.

Kada se zanemare teorijska objašnjenja, vidljivo je da su svi AI alati zadatke riješili točno te bi prema tome ostvarili maksimalna četiri boda prema uputama za bodovanje koje je objavio NCVVO.

b) Srednji upit

Većina AI alata zadatak je riješila točno. Gemini je napravio grešku u računu s potencijama i uz točan postupak dao netočan rezultat za silu električnog polja, što je dovelo do netočnog konačnog rezultata. Nakon dodatnog upita u kojem je dobio naputak da provjeri račun u tom koraku, ispravio je pogrešku i ostatak računa koji se nadovezuje na taj korak.

ChatGPT i Grok analizirali su dobiveno rješenje, dok je samo Claude ponudio grafički prikaz problemske situacije.

Razina objašnjenja bila je detaljnija u odnosu na prošli upit. Gemini i Grok u tome su bili nešto detaljniji.

I u ovom slučaju zabilježena je povremena neprecizna uporaba fizikalne terminologije.

Odgovorom na ovaj upit Gemini bi dobio tri boda na ispitu državne mature, dok bi ostali alati dobili maksimalna četiri boda.

c) Napredan upit

Kod Geminija je ponovno uočena ista pogreška u računu s potencijama prilikom izračuna sile električnog polja. Pogreška je nakon dodatnog upita ispravljena. Ostali alati zadatak su riješili točno.

Postupci rješavanja bili su detaljni i sistematični i uključivali su analizu dobivenih rezultata.

Razina objašnjenja većinom se ne razlikuje od one dobivene srednjim upitom. Svi alati dali su fizikalnu interpretaciju dobivenog rezultata.

Claude je generirao najdetaljniji grafički prikaz problemske situacije, ChatGPT i Grok su ponudili jednostavnije skice, a Gemini je taj korak u potpunosti preskočio.

I ovdje se primjećuje neprecizna i netočna uporaba fizikalne terminologije.

Odgovorom na ovaj upit Gemini bi dobio tri boda na ispitu državne mature, dok bi ostali alati dobili maksimalna četiri boda.

4.2. Zadatak 28

a) Jednostavan upit

Svi analizirani AI alati uspješno su riješili zadatak i primijenili odgovarajući postupak.

ChatGPT i Claude su prilikom rješavanja zadatka dali kraća objašnjenja, ali nisu ponudili tumačenja dobivenog rezultata. Gemini je bio najdetaljniji u objašnjavanju postupka rješavanja i tumačenju dobivenog rješenja.

Kod Geminija je uočena neujednačena uporaba zapisa brojeva prilikom pretvorbe mjernih jedinica.

Svi alati umjetne inteligencije na državnoj maturi bi ostvarili tri boda što je za ovaj zadatak najveći mogući broj bodova.

b) Srednji upit

Svi alati dali su točno rješenje i postupno objasnili korake rješavanja. ChatGPT je u svom objašnjenju bio najsažetiji, a Grok je ponudio metodičniji pristup rješavanja od ostalih alata. Claude je uključio skicu, iako se u ovom upitu ona nije tražila.

Svi alati ponudili su interpretaciju dobivenog rezultata.

Svi alati umjetne inteligencije na državnoj maturi bi ostvarili tri boda, što je za ovaj zadatak najveći mogući broj bodova.

c) Napredan upit

Svi alati zadatak su riješili točno i postupno uz detaljno objašnjenje svakog koraka, te su napravili analizu i fizikalnu interpretaciju dobivenog rezultata.

Gemini jedini od alata nije prikazao skicu fizikalnog problema.

ChatGPT je zadovoljio sve tražene elemente, ali je u svojim objašnjenjima bio najsažetiji.

Svi alati umjetne inteligencije na državnoj maturi bi ostvarili tri boda što je za ovaj zadatak najveći mogući broj bodova.

4.3. Zadatak 25

a) Jednostavan upit

Svi AI alati zadatak su riješili točno te bi za dobiveni rezultat postigli dva boda na državnoj maturi (maksimalan broj bodova).

Postupak rješavanja bio je sažet i temeljen na primjeni odgovarajuće formule.

Alati su, osim ChatGPT-a, dali kratko teorijsko objašnjenje Carnotovog toplinskog stroja, iako se to od njih nije tražilo.

b) Srednji upit

AI alati zadatak su riješili točno i sistematično te su ga objasnili detaljno po koracima. ChatGPT je u objašnjenjima najsažetiji. Grok i Claude daju detaljniju interpretaciju

rezultata. Iako se to nije tražilo, Claude je generirao sliku toplinskog stroja, a Gemini grafikon Carnotovog kružnog procesa.

Svi alati ostvarili bi dva boda na ispitu državne mature.

c) Napredan upit

Svi alati zadovoljili su sve postavljene kriterije upita. Zadatak je riješen i objašnjen po koracima, a skica toplinskog stroja prisutna je u svim odgovorima, kao i detaljan opis fizikalnog problema i analiza dobivenog rješenja.

Na ispitu državne mature AI alati ovim postupkom rješavanja ostvarili bi dva boda.

Tablica 4: Procjena AI alata različitih generacija i tehničkih razina prema kriterijima analize odgovora

Kriterij	**ChatGPT (GPT-4o)**	**Claude (Claude Sonnet 4.6)**	**Gemini (Gemini 2.0 Flash)**	**Grok (Grok 3)**
Generacija/Razina	Standardni vodeći model	Napredni vodeći model s odmakom u razvoju	Brzi (Flash) model	Napredni model nove generacije
Ključna značajka	Svestranost i uravnoteženost	Prošireno razmišljanje	Brzina i multimodalnost	Strukturirana logika
točnost rješenja zadatka	Sve točno	Sve točno	Pogreška u Z32	Sve točno
usklađenost s metodološkim postupkom rješavanja	Da	Da	Da	Da
jasnoća i razina objašnjenja postupka rješavanja zadatka	U skladu s upitom	U skladu s upitom	U skladu s upitom; najdetaljniji i najopširniji	U skladu s upitom
terminološka točnost	Povremena zamjena pojmova	Da	Da	Povremena zamjena pojmova
vizualizacija problema	Da, kada se traži	Da, najdetaljnija	Uglavnom izostavlja	Da, kada se traži
prisutnost analize i interpretacije rezultata	Za srednji i napredan upit	Za srednji i napredan upit	Da	Da, najdetaljnija

Izvor: autor

Radi lakše usporedbe i pregleda rezultata, kvalitativni opisi i procjene dobiveni analizom odgovora prevedeni su u brojčane vrijednosti ordinalne skale prikazane u Tablici 5. Svaki kriterij analize procijenjen je za svaki AI alat i razinu upita jednom od pet opisnih kategorija. Kategorijama su zatim pridodane odgovarajuće numeričke vrijednosti: uvijek (5) znači da je kriterij u potpunosti i dosljedno ispunjen u odgovoru; gotovo uvijek (4) znači da je ispunjen u većini slučajeva; djelomično (3) da je ispunjen samo u dijelu odgovora; gotovo nikada (2) da je rijetko ispunjen, s ponekom iznimkom; dok nikada (1) označava da kriterij nije ispunjen niti u jednom dijelu odgovora.

Tablica 5: Procjena AI alata ordinalnom skalom kvalitete odgovora

Kvalitativni kriterij	ChatGPT (GPT-4o)	Claude (Claude Sonnet 4.6)	Gemini (Gemini 2.0 Flash)	Grok (Grok 3)
točnost	5	5	4	5
metodologija	5	5	5	5
jasnoća	4	4	5	4
terminologija	3	5	5	3
vizualizacija	4	5	1	4
analiza	4	4	5	5

Izvor: autor

Postupak prevođenja kvalitativnih opisa u ordinalnu skalu omogućuje grafički prikaz i usporedbu alata i dobivenih rezultata, što je prikazano na Slici 3. Važno je napomenuti i naglasiti da su dodijeljene vrijednosti rezultat procjene autora, a ne mjerljive veličine, što predstavlja temeljno ograničenje ovakvog metodološkog pristupa.

Slika 3: Usporedba AI alata prema ordinalnoj skali kvalitete odgovora

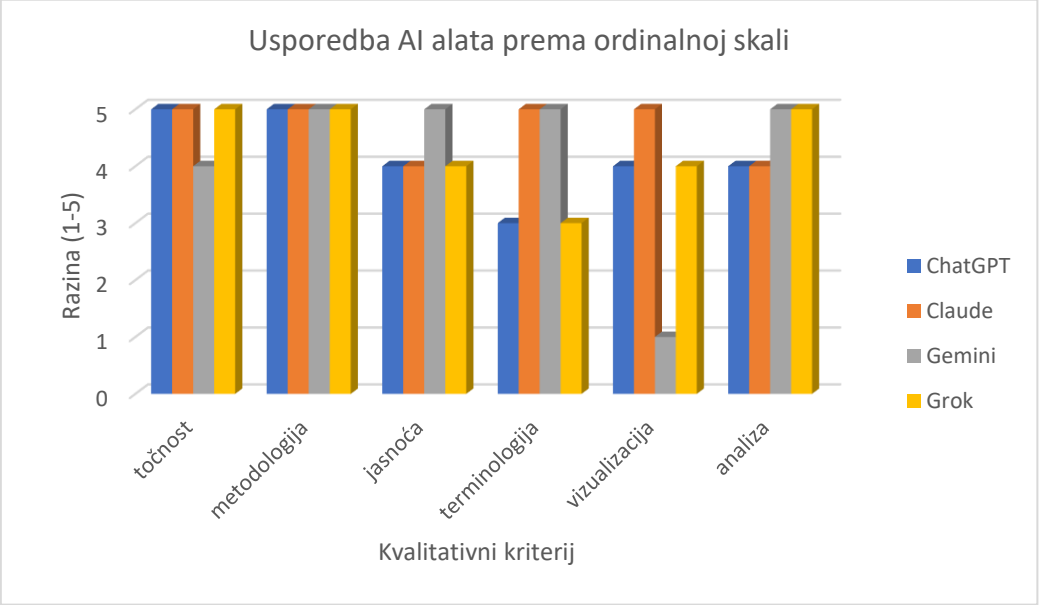

Izvor: autor

5. Rasprava

Na početku treba naglasiti da je ovo istraživanje provedeno na ograničenom uzorku od tri zadatka iz jednog ispitnog roka, što posljedično ograničava mogućnost generalizacije rezultata. Pri tome procjena kvalitete odgovora uključuje subjektivni element u dijelu koji se odnosi na didaktičku vrijednost, razinu i jasnoću objašnjenja. Svi alati korišteni su u svojim besplatnim verzijama koje nude značajno manje mogućnosti u odnosu na komercijalne inačice. Modeli su

testirani na osnovnim (najnižim) razinama, ali upravo te verzije učenici najčešće i koriste u svom radu.

Pri tumačenju rezultata važno je uzeti u obzir i različitu prirodu te ograničenja testiranih modela. Korišteni alati pripadaju različitim generacijama i imaju različite namjene. Primjerice, Gemini 2.0 Flash, koji je optimiziran za brzu obradu podataka, u svim je zadacima izostavio vizualizaciju problemske situacije, čak i kada se to izričito tražilo, ali je ponudio najdetaljnija tekstualna objašnjenja. To je u potpunosti u skladu s arhitekturom modela koja daje prednost brzom generiranju teksta. Claude Sonnet 4.6, jedini od testiranih modela, posjeduje mogućnost proširenog zaključivanja, a ujedno je bio i jedini koji je dosljedno generirao detaljne grafičke prikaze te nije pokazivao terminološke nedosljednosti. GPT-4o i Grok 3 ponudili su uravnotežene rezultate prema svim kriterijima, dok se kod njih povremeno pokazala terminološka nedosljednost, neovisno o složenosti upita.

Analiza rezultata pokazuje da ispitani AI alati u većini slučajeva uspješno rješavaju zadatke iz fizike na razini državne mature. Netočan rezultat koji je alat Gemini dobio u zadatku 32 nije rezultat pogreške u fizikalnom postupku, nego pogreške koja je nastala prilikom računanja s potencijama. Uočeno je da se pogreške ne odnose na konceptualno razumijevanje fizikalnog problema, već uglavnom na računske operacije.

Rezultati jasno pokazuju da složenost i preciznost upita značajno utječu na kvalitetu dobivenih odgovora. Već kod jednostavnog upita umjetna inteligencija daje postupno rješenje koje učenike koji posjeduju određeno proceduralno znanje i temeljne matematičke vještine može dovesti do viših razina primjene, analize i vrednovanja. S preciznijim postavljanjem upita povećava se i dubina odgovora na način da je teorijska pozadina fizikalnog problema detaljno objašnjena. Na taj način i učenici koji do tada nisu posjedovali potrebno konceptualno i/ili proceduralno znanje, nakon proučavanja dobivenih odgovora mogu primijeniti opisani postupak na rješavanje problema.

U svojim detaljnim odgovorima umjetna inteligencija je identificirala ciljeve rješavanja problema, izabrala potrebne informacije, konstruirala plan rješavanja problema, vizualizirala problem, pretvarala mjerne jedinice, matematički modelirala problem i računala potrebne fizičke veličine te vrednovala fizičke situacije, postupke i rezultat. Ukratko, prema ispitnom katalogu državne mature (NCVVO, 2025a) zadatke je rješavala na način potreban za ostvarivanje obrazovnog ishoda „rješava fizičke probleme“. Prema tome, rezultati istraživanja upućuju na to da umjetna inteligencija može pružiti kvalitetnu podršku učenicima u nastavi fizike, osobito u procesu uvježbavanja i ponavljanja gradiva.

Uočeno je kako razina objašnjenja, odnosno tekstualnog opisa rješavanja zadatka i teorijske pozadine, nije uvijek prilagođena učenicima s nižom razinom predznanja. Isto tako, ponekad se dubina objašnjavanja ne razlikuje značajno s obzirom na složenost upita. U pojedinim slučajevima prisutna je neprecizna i netočna terminologija, što može dovesti do pogrešnog razumijevanja fizikalnih pojmova. Sve navedeno potvrđuje važnost kritičkog pristupa korištenju umjetne inteligencije u učenju.

6. Zaključak

Analizom rješenja zadataka koja su ponudili alati umjetne inteligencije zaključuje se da umjetna inteligencija može učenicima pomoći u rješavanju i razumijevanju numeričkih zadataka, odnosno pomoći učeniku u ostvarivanju obrazovnog ishoda rješavanje fizičkih problema.

Kako će učenik postaviti pitanje i hoće li, nakon što dobije odgovor koji ga nije u potpunosti zadovoljio, postaviti dodatno potpitanje, u velikoj mjeri ovisi o njemu i njegovoj unutarnjoj motivaciji. Ako je učenik motiviran, umjetna inteligencija bit će mu od velike pomoći prilikom rješavanja zadataka za vježbu, pripremanja pisanih provjera znanja i ispita državne mature. Učenicima koji nemaju motivaciju za samostalno rješavanje zadataka, ona će poslužiti tek za dobivanje brzog i gotovog rješenja.

Ono što umjetna inteligencija ne može napraviti jest potaknuti učenika na samostalan rad i dati mu povratnu informaciju o napretku. Ne može samostalno, bez prethodno dobivene upute, prilagoditi svoj pristup učeniku i njegovim sposobnostima. Umjetna inteligencija za sada ne može zamijeniti nastavnika, ali i njemu i učeniku može biti jako dobar pomoćnik u radu.

Sve veći broj učenika redovito koristi umjetnu inteligenciju za potrebe škole. Jedan od novih nastavničkih zadataka koje donosi obrazovanje u vrijeme umjetne inteligencije jest pomoći im u kreiranju kvalitetnijih upita prilagođenih njihovim potrebama. To podrazumijeva razvoj vještina preciznog formuliranja pitanja, jasnog definiranja problema i razine na kojoj problem treba biti riješen. Važno je poticati učenike na postavljanje dodatnih potpitanja, provjeru dobivenih odgovora i kritičko promišljanje o njihovu sadržaju.

Literatura

1. Anthropic. (2025). Extended thinking. https://docs.anthropic.com/en/docs/build-with-claude/extended-thinking [15.6.2026.]
2. Cerovac, I., i Černeha, I. (2025). *Umjetna inteligencija u učionici: Rousseauovski pogled na učenje i tehnologiju*. U: K. Mrnjaus, S. Kušić, i S. Vrcelj (ur.), Obrazovanje u doba umjetne inteligencije (str. 67–85). FFRI. https://izdavastvo.ffri.hr/wp-content/uploads/2025/09/Mrnjaus_Kusic_Vrcelj_Obrazovanje-u-doba-umjetne-inteligencije_final.pdf
3. Češi, M. (2024). *Što je što u nastavi.* Ljevak.
4. Europska komisija. (2019). *Ethics guidelines for trustworthy AI*. https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai [30.3.2026.]
5. Google DeepMind. (2025). Gemini 2.0 model updates: 2.0 Flash, Flash-Lite, Pro Experimental. https://blog.google/technology/google-deepmind/gemini-model-updates-february-2025/ [15.6.2026.]
6. Komar, Z. (2025). *Problem autentičnosti kao bitne dimenzije obrazovanja u doba umjetne inteligencije*. U: K. Mrnjaus, S. Kušić, i S. Vrcelj (ur.), Obrazovanje u doba umjetne inteligencije (str. 13-41). FFRI. https://izdavastvo.ffri.hr/wp-content/uploads/2025/09/Mrnjaus_Kusic_Vrcelj_Obrazovanje-u-doba-umjetne-inteligencije_final.pdf
7. Krsnik, R. (2008). *Suvremene ideje u metodici nastave fizike*. Školska knjiga.
8. Kuhar, L. (2007). *Primjena matematičkih modela u metodologiji rješavanja numeričkih zadataka iz fizike*. Metodički obzori, 2(1), 120-126. https://hrcak.srce.hr/19446
9. Mrnjaus, K., Vrcelj, S., i Kušić, S. (2023). *Umjetna inteligencija i obrazovanje: Suparnici ili saveznici?* JAHR – Europski časopis za bioetiku, 14(2), 429–445. https://hrcak.srce.hr/file/454406
10. NCVVO. (2025a). *Fizika: Ispitni katalog za državnu maturu u školskoj godini 2025./2026.* Nacionalni centar za vanjsko vrednovanje obrazovanja. https://www.ncvvo.hr/wp-content/uploads/2025/09/FIZ-2026.pdf
11. NCVVO. (2025b). Provedeni ispiti: Državna matura 2024./2025. – prvi rok. Nacionalni centar za vanjsko vrednovanje obrazovanja. https://www.ncvvo.hr/drzavna-matura-2024-2025-prvi-rok/

12. Novosel, N. (2017). *Konceptualno razumijevanje Newtonovih zakona i primjena na rješavanje zadataka.* U: I. Aviani (ur.), XIII. hrvatski simpozij o nastavi fizike: Suvremeni kurikul i nastava fizike, zbornik radova (str. 95–102). Hrvatsko fizikalno društvo. https://www.researchgate.net/publication/357239805 [17.6.2026]
13. OpenAI. (2024). Hello GPT-4o. https://openai.com/index/hello-gpt-4o/ [15.6.2026.]
14. Stipaničev, I., Šerić, M., i Braović, A. (2021). *Uvod u umjetnu inteligenciju*. Fakultet elektrotehnike, strojarstva i brodogradnje. https://ai.fesb.hr/knjiga/AI-knjiga-FINAL.pdf [30.3.2026]
15. Topolovčan, T., i Vanek, K. (2025). *Obrazovanje, škola i umjetna inteligencija: prema reformnoj pedagogiji 21. stoljeća?*. U: K. Mrnjaus, S. Kušić, & S. Vrcelj (ur.), Obrazovanje u doba umjetne inteligencije (str. 42-66). FFRI. https://izdavastvo.ffri.hr/wp-content/uploads/2025/09/Mrnjaus_Kusic_Vrcelj_Obrazovanje-u-doba-umjetne-inteligencije_final.pdf
16. xAI. (2025). Grok 3 Beta — The Age of Reasoning Agents. https://x.ai/news/grok-3 [15.6.2026.]

Dodatak (poveznice na upite, upiti postavljeni 11.-15.4.2026.)

1. Zadatak 32

1) Jednostavan upit
    a. ChatGPT: https://chatgpt.com/share/69db4c80-7c50-8384-849f-71f5310b3876
    b. Claude: https://claude.ai/share/2798a4a5-0858-4737-89ce-ecfadff2116b
    c. Gemini: https://gemini.google.com/share/0ce1791f6d0d
    d. Grok: https://grok.com/share/bGVnYWN5_a2bcc944-0540-464f-89e8-6dcfab273dfa
2) Srednji upit
    a. ChatGPT: https://chatgpt.com/share/69dfe198-68d0-832c-bb8f-cf8b0cf31868
    b. Claude: https://claude.ai/share/24606635-82b5-43e1-bb81-e2021e40e401
    c. Gemini: https://gemini.google.com/share/929d91643269
    d. Grok: https://grok.com/share/bGVnYWN5_e783459a-5179-4155-bd68-775ab86dce2c
3) Napredan upit
    a. ChatGPT: https://chatgpt.com/share/69dfdfd4-ea20-8385-ac4a-c7506cf4beb0

b. Claude: https://claude.ai/share/9bc74fa3-75d9-4b9f-878c-6d2c59f04d24
c. Gemini: https://gemini.google.com/share/7b9d7ed801b0
d. Grok: https://grok.com/share/bGVnYWN5_b61fb67d-31d3-4e68-b270-e397f096ac5f

2. Zadatak 28

1) Jednostavan upit
   a. ChatGPT: https://chatgpt.com/share/69dfe1e0-8d94-838d-8dae-c5ecf80d9eaa
   b. Claude: https://claude.ai/share/bdb5bdf7-290a-4eb2-91c3-4dd085569db3
   c. Gemini: https://gemini.google.com/share/017e65556c19
   d. Grok: https://grok.com/share/bGVnYWN5_9c615d21-3018-4405-b9a5-682f532e6e82
2) Srednji upit
   a. ChatGPT: https://chatgpt.com/share/69dfe1f2-2fd4-8328-8393-ca85e04773df
   b. Claude: https://claude.ai/share/351296a4-39e6-4430-8a17-ac003907a9ee
   c. Gemini: https://gemini.google.com/share/f297d7d5c00c
   d. Grok: https://grok.com/share/bGVnYWN5_4259e07b-6ae7-452e-80f2-d816791ab8a6
3) Napredan upit
   a. ChatGPT: https://chatgpt.com/share/69dfe1ff-03e4-8326-92f6-1e211403312f
   b. Claude: https://claude.ai/share/a601043e-1b9e-479d-ab91-25815c6e7d05
   c. Gemini: https://gemini.google.com/share/b935e92e36a5
   d. Grok: https://grok.com/share/bGVnYWN5_275bd627-6712-464b-b9fa-2671ac7a7659

3. Zadatak 25

1) Jednostavan upit
   a. ChatGPT: https://chatgpt.com/share/69dfe217-3cf8-832d-b0e4-ab3330e18c56
   b. Claude: https://claude.ai/share/1142c9af-b334-4138-b22a-c9f11cb3f8de
   c. Gemini: https://gemini.google.com/share/8ec31001045a
   d. Grok: https://grok.com/share/bGVnYWN5_2e3973d9-38a1-4b1a-a413-695332d14c5e
2) Srednji upit
   a. ChatGPT: https://chatgpt.com/share/69dfe270-09a4-832a-89ff-520a8c60eab3

b. Claude: https://claude.ai/share/40bb1582-0480-47a9-a97a-a60e669c5a1c
c. Gemini: https://gemini.google.com/share/9fc890628466
d. Grok: https://grok.com/share/bGVnYWN5_b974b641-2554-4538-8fb8-d5b8a992d12b

3) Napredan upit
   a. ChatGPT: https://chatgpt.com/share/69dfe282-d470-832c-9b94-ed2fb0fb19d5
   b. Claude: https://claude.ai/share/f054e053-7b64-45b7-b3ed-979afcdc9e50
   c. Gemini: https://gemini.google.com/share/36753a5064c9
   d. Grok: https://grok.com/share/bGVnYWN5_9e31aa8f-60c2-4dfc-b142-ba44b7d8aaab