Suradničko i problemsko učenje u doba umjetne inteligencije

Sanja Pavlović Šijanović | 7 travnja, 2026

Sažetak: U ovom se članku analitički razmatraju pedagoške promjene u suradničkom i problemskom učenju koje proizlaze iz sve intenzivnije primjene sustava umjetne inteligencije u visokom obrazovanju. Promatra se utjecaj umjetne inteligencije na oblikovanje problemskih zadataka, dinamiku timskog rada i procese zajedničkog rješavanja problema te potreba za redefiniranjem nastavnih pristupa u digitalno posredovanom okruženju. U članku se razlaže uloga digitalnih alata temeljenih na sustavima umjetne inteligencije u planiranju, strukturiranju i evaluaciji timskog rada te rizici koje njihova primjena otvara u području akademskog integriteta, transparentnosti rada i procjene autentičnog studentskog doprinosa. Analiziraju se i razvojne razlike među studentima, osobito u razini digitalnih kompetencija, koje mogu utjecati na ravnopravnost sudjelovanja u timskim aktivnostima i zahtijevaju ciljanu pedagošku podršku. Na temelju uočenih trendova i izazova predlažu se smjernice za odgovornu i pedagoški utemeljenu integraciju umjetne inteligencije u visokoškolsko poučavanje, koje uključuju kritičko korištenje tehnologije, jasnu regulaciju uporabe alata temeljenih na sustavima umjetne inteligencije te poticanje razvoja viših razina mišljenja i suradničkih vještina.

Uvod

Suradničko i problemsko učenje već su desetljećima prepoznati kao važni pedagoški pristupi u visokom obrazovanju što potvrđuju brojni autori i istraživanja koja ističu njihov doprinos razvoju kritičkog mišljenja, rješavanju složenih problema i učinkovitom timskom radu (Jaganathan, Ramesh, i Krishnan 2020, Strobel i van Barneveld, 2009). Razvojem naprednih sustava umjetne inteligencije znatno se mijenja način na koji studenti pristupaju zadacima, komuniciraju, organiziraju rad i oblikuju rješenja, što otvara prostor za nove pedagoške mogućnosti, ali i zahtijeva prilagodbu postojećih obrazovnih pristupa.

Međunarodne analize ukazuju da će sustavi umjetne inteligencije sve snažnije utjecati na funkcioniranje visokog obrazovanja te preoblikovati ustaljene obrasce poučavanja, učenja i institucionalnog upravljanja (Akinwalere i Ivanov 2022, 1–2). U kontekstu sve intenzivnijeg prikupljanja i analize digitalnih tragova studenata, koji postaju temelj za razumijevanje obrazovnih potreba i oblikovanje pedagoških intervencija, umjetna inteligencija otvara nove mogućnosti za personalizaciju, praćenje učenja i razvoj suradničkih aktivnosti (Akinwalere i Ivanov 2022, 2). Prema UNESCO-u (2023) i OECD-u (2023), ovi sustavi utječu na sve razine obrazovnog procesa počevši od oblikovanja zadataka pa sve do procjene studentskog rada te zahtijevaju odgovorne i promišljene pedagoške prilagodbe. U ovom se članku razmatra kako umjetna inteligencija preoblikuje suradničke i problemske aktivnosti te na koje načine visokoškolski nastavnici mogu prilagoditi dizajn nastave i metode vrednovanja u digitalno posredovanom okruženju.

Utjecaj umjetne inteligencije na suradničko učenje

Integracija umjetne inteligencije značajno mijenja dinamiku suradničkog učenja. Tehnologije temeljene na umjetnoj inteligenciji sve više djeluju kao posrednici u komunikaciji, koordinaciji i razmjeni ideja, čime studentima olakšavaju strukturiranje zadataka, organizaciju rada i pristup relevantnim informacijama (Onyejele et al 2024, 27–28). Prema Onyejele i sur. (2024, 28), umjetna inteligencija pritom ne djeluje samo kao instrument (tehničko pomagalo), nego kao agent koji aktivno sudjeluje u procesu suradničkog učenja, omogućuje studentima razmjenu ideja i izvora, potiče zajedničko razvijanje rješenja te unapređuje timsku i komunikacijsku dinamiku. Za razliku od digitalnih alata koji su studentima prvenstveno omogućivali razmjenu dokumenata, komunikaciju i

osnovnu koordinaciju rada, sustavi potpomognuti umjetnom inteligencijom uvode kvalitativno drukčiju razinu potpore suradničkom učenju. Oni mogu analizirati i sintetizirati informacije u stvarnom vremenu, predlagati moguće pristupe rješavanju problema, prepoznati obrasce u timskoj interakciji te povezivati različite izvore znanja u koherentne smislene cjeline. Iako takvi alati uvelike olakšavaju timsku interakciju, koordinaciju i suradnju, njihova prisutnost može dovesti do pasivnijeg uključivanja pojedinih članova tima ako se unaprijed ne postave jasna pravila korištenja. U takvom je okruženju osobito važna uloga nastavnika koji usmjerava tijek suradnje i prati način na koji studenti koriste alate umjetne inteligencije. S obzirom na izazove koje ova tehnologija donosi, učinkovitijim se pokazuje oblikovanje aktivnosti u kojima umjetna inteligencija služi kao potpora suradnji, a ne kao zamjena za aktivni angažman studenata. Kako bi takav pristup doista poticao kvalitetno zajedničko učenje, nužan je razvoj komunikacijskih i metakognitivnih vještina poput planiranja, praćenja i evaluacije vlastitog učenja i rada, kritičkog vrednovanja informacija te prilagodbe strategija učenja prema potrebama tima. Ove vještine omogućuju studentima procjenu kvalitete i vjerodostojnosti informacija generiranih umjetnom inteligencijom, njihovu argumentiranu integraciju u zajednički rad te kritičko sagledavanje učinkovitosti i dinamike suradnje (Onyejele et al. 2024, 28).

Redefiniranje problemskih zadataka u okruženju umjetne inteligencije

Sve izraženija primjena sustava umjetne inteligencije u obrazovanju iziskuje temeljito preispitivanje načina oblikovanja problemskih zadataka. Tradicionalni problemski zadaci, koji su se oslanjali na ručnu obradu podataka, analizu literature i linearno rješavanje, danas su lako izvedivi pomoću generativnih modela i automatiziranih digitalnih alata (Jones 2024). Stoga se u suvremenoj praksi sve učestalije naglasak stavlja na zadatke koji potiču višerazinsko promišljanje, argumentaciju, evaluaciju izvora i refleksiju o procesu rješavanja (Scholkmann et al. 2025, 15-19).

Sve izraženija primjena sustava umjetne inteligencije u obrazovanju iziskuje temeljito preispitivanje načina oblikovanja problemskih zadataka. Tradicionalni problemski zadaci, poput izrade analitičkog osvrta na zadani skup podataka ili problemske esejske analize temeljene na dostupnoj literaturi, nekoć su zahtijevali ručnu obradu informacija, opsežno pretraživanje izvora i linearan pristup rješavanju. Danas generativni modeli poput GPT-5 i Google Gemini, zajedno s automatiziranim digitalnim alatima za analizu podataka kao što su Google Colab, Tableau ili Microsoft Power BI, mogu u kratkom vremenu proizvesti ili oblikovati temeljne sastavnice takvih zadataka (Jones 2024). Stoga se u suvremenoj praksi sve učestalije naglasak stavlja na složenije problemske zadatke koji potiču višerazinsko promišljanje, argumentaciju, evaluaciju izvora i refleksiju o tijeku rješavanja (Scholkmann et al. 2025, 15–19). Primjerice, u STEM području složeniji zadatak može uključivati razvoj prototipa ili gotovog rješenja za stvarni tehnički problem uz obvezu usporedbe više mogućih pristupa, evaluacije tehničkih i etičkih ograničenja te dokumentiranja logike i faza rješavanja.

U takvim zadatcima umjetna inteligencija može predstavljati vrijedan dodatni resurs koji obogaćuje proces učenja, ali njezina uloga ostaje dopunska u odnosu na kognitivne procese koje razvijaju studenti. Očuvanje autentičnosti studentskog doprinosa povezuje se s jasnom strukturom i fazama rješavanja zadatka, definiranjem očekivanih kompetencija i postavljenim granicama uporabe alata temeljenih na umjetnoj inteligenciji. Studenti se pritom potiču na usporedbu različitih prijedloga koje umjetna inteligencija može generirati, prepoznavanje potencijalnih pogrešaka te donošenje utemeljenih i argumentiranih zaključaka (Hudson 2023).

Budući da generativni modeli mogu preuzeti značajan dio analitičkog procesa, problemske je zadatke opravdano oblikovati tako da uključuju transparentno prikazivanje tijeka rada i obrazlaganje odluka donesenih tijekom rješavanja. Generativni modeli mogu preuzeti dio analitičkog procesa automatiziranjem ranih faza obrade informacija, primjerice sažimanjem opsežnih tekstualnih izvora, izdvajanjem temeljnih koncepata ili predlaganjem preliminarnih struktura argumentacije. Stoga je zadatke opravdano oblikovati tako da uključuju transparentno prikazivanje tijeka rada i obrazlaganje odluka donesenih tijekom rješavanja.

Učinkovitim se pokazuje uključivanje faza u kojima studenti kritički uspoređuju različite generirane prijedloge, analiziraju njihovu kvalitetu i oblikuju vlastita rješenja. Jones (2024) ističe da refleksija o ulozi umjetne inteligencije u cjelokupnom procesu rješavanja problema pridonosi sveobuhvatnijem razumijevanju sadržaja i razvoju analitičkog mišljenja. Takvim se pristupom umjetna inteligencija integrira kao podrška učenju, dok odgovornost za kvalitetu i izvornost rješenja ostaje u domeni studenata i nastavnika koji prate i usmjeravaju njihov rad.

Digitalni alati koji integriraju umjetnu inteligenciju i njihova primjena u timskom radu

Digitalni alati temeljeni na umjetnoj inteligenciji sve se češće koriste za organiziranje, strukturiranje i praćenje timskog rada. Platforme za zajedničko pisanje i upravljanje projektima Microsoft Teams Copilot, Microsoft Loop, Notion AI ili Trello AI mogu automatski sažimati rasprave, predlagati sljedeće korake ili vizualizirati tijek rada, čime pridonose učinkovitijoj koordinaciji timova. Generativni alati ChatGPT, Google Gemini, Canva AI ili Jasper AI omogućuju brzo prototipiranje ideja, izradu skica, analizu podataka ili simulaciju mogućih rješenja, što ubrzava početne faze rješavanja problema. Istovremeno, alati za dokumentiranje procesa, kao što su GitHub Classroom ili platforme za analitiku timske suradnje poput Microsoft Viva Insights, nastavnicima pružaju uvid u obrasce suradnje i razinu angažmana pojedinih studenata. Iako ovi alati povećavaju produktivnost i transparentnost, njihova primjena zahtijeva definirane etičke smjernice, načine provjere autentičnosti studentskog rada te promišljenu integraciju u didaktički dizajn kako bi podržali razvoj suradničkih kompetencija, a ne ih zamijenili (Dabis 2024, 1-7).

Akademski integritet, evaluacija i razvojne razlike studenata

Integracija sustava umjetne inteligencije u suradničko i problemsko učenje otvara niz izazova koji zahtijevaju pažljivo pedagoško i institucionalno promišljanje (Scholkmann et al. 2025, 15–19). Jedan od najistaknutijih izazova povezan je s akademskim integritetom, jer generativni alati mogu proizvesti sadržaje koji prikrivaju razinu stvarnog studentskog doprinosa te otežavaju razlikovanje autentičnog rada od automatiziranih rješenja. U takvim okolnostima važnom se pokazuje jasna regulacija uporabe umjetne inteligencije, uključujući transparentno navođenje korištenih alata, označavanje elemenata generiranih uz njihovu potporu te povećana usmjerenost na vrednovanje procesa, a ne samo završnog proizvoda. Pitanje evaluacije suradničkog rada dodatno se ističe u okruženju u kojem se koriste alati temeljeni na umjetnoj inteligenciji. Iako analitički sustavi mogu pružiti uvid u intenzitet i raspodjelu aktivnosti unutar tima, takvi podaci ne mogu u potpunosti zamijeniti kvalitativnu procjenu angažmana, kritičkog mišljenja i odgovornosti pojedinih studenata. Oni bilježe kvantitativne pokazatelje sudjelovanja, ali ne i dubinu razumijevanja, kvalitetu argumentacije niti doprinos oblikovanju zajedničkih rješenja (Riordan et al. 2024, 4–10).

U ovakvom okruženju postaju izraženije i razvojne razlike među studentima. Studenti koji posjeduju naprednije digitalne kompetencije brže ovladavaju alatima temeljenima na umjetnoj inteligenciji, dok studentima s manje iskustva može biti potrebna dodatna podrška kako bi ravnopravno sudjelovali u suradničkim aktivnostima (Mena-Guacas et al. 2024, 2–8). Stoga je osiguravanje pravednih uvjeta rada, primjena inkluzivnih strategija potpore te sustavno poticanje razvoja kompetencija za odgovorno i kritičko korištenje tehnologija potpomognutih umjetnom inteligencijom nužan element stvaranja uravnoteženog i poticajnog okruženja za učenje.

Zaključak

Umjetna inteligencija donosi značajne promjene u načinu na koji se oblikuju i provode suradničke i problemske aktivnosti u visokom obrazovanju. Iako umjetna inteligencija može unaprijediti dostupnost informacija, olakšati organizaciju timskog rada i potaknuti inovativne pristupe rješavanju problema, njezina primjena zahtijeva pažljivo dizajnirane pedagoške strategije koje će osigurati aktivno sudjelovanje studenata i očuvanje autentičnosti njihovih doprinosa. Učinkovita integracija

umjetne inteligencije podrazumijeva jasna pravila korištenja, transparentnost u procesu rada te usmjerenost na razvoj kompetencija koje nadilaze tehničke vještine. Nastavnici imaju važnu ulogu u oblikovanju poticajnih i odgovornih digitalnih okruženja te u praćenju etičkih, metodoloških i organizacijskih aspekata uporabe umjetne inteligencije. U toj ulozi nastavnici određuju pedagoški opravdano korištenje alata temeljenih na sustavima umjetne inteligencije, uspostavljaju jasna pravila njihove uporabe te nadziru njihovu primjenu kako bi očuvali akademski integritet i potaknuli samostalno, argumentirano učenje. Odgovornim i svrhovito oblikovanim pristupom moguće je postići ravnotežu između tehnoloških mogućnosti i pedagoških ciljeva, čime se stvara okruženje u kojem umjetna inteligencija nadopunjuje aktivno i kritičko učenje studenata.