18.11.2026. 13:22
Pogledano: 66 puta

AI kao učesnik nastavnog procesa | Amra Tumbul

Kada je tačan odgovor udaljen nekoliko sekundi, šta ostaje od učenja? Tekst Amre Tumbul o AI-ju, znanju i novoj ulozi nastavnika.



Autorica: Amra Tumbul, studentica pedagogije

Kad god se u obrazovanju pojavila nova tehnologija, postavljalo se pitanje da li ona samo olakšava rad ili mijenja i način na koji učimo. Vještačka inteligencija ipak je poseban slučaj, jer ne pohranjuje i ne pronalazi informacije, nego proizvodi tekst, objašnjenja i rješenja, odnosno sve ono što smo do sada smatrali dokazom da je neko nešto naučio.

Suština učenja ne leži u tome da se dođe do tačnog odgovora, nego u promjeni koja se pritom dešava u samom učeniku. Učiti znači razumjeti, povezati nove spoznaje s onim što već znamo, primijeniti ih u novim situacijama i, na kraju, steći sposobnost da samostalno razmišljamo i prosuđujemo. Ta promjena se postiže naporom: pokušajem, griješenjem, ispravljanjem i ponovnim pokušajem. Zato se suština učenja vidi u trajnom znanju i razvijenim sposobnostima, a ne u završenom zadatku ili uredno napisanom radu. Alati, bilo da je riječ o knjizi, kalkulatoru, internetu ili vještačkoj inteligenciji, služe da taj proces olakšaju, ubrzaju ili obogate, ali ga ne mogu obaviti umjesto učenika.

> Upravo zato je važno razlikovati sredstvo od cilja: kada alat pomaže učeniku da bolje razumije, on podržava učenje, a kada mu samo omogućava da proizvede rezultat bez razumijevanja, **rezultat postoji, a učenja nema.** Ta razlika je polazna tačka za razumijevanje uloge vještačke inteligencije u obrazovanju i značaja nastavnika u njemu.

Kada je informacija uvijek pri ruci

Sparrow, Liu i Wegner (2011) su kroz četiri studije pokazali da ljudi koji očekuju da će informaciji ponovo imati pristup slabije pamte samu informaciju, a bolje pamte gdje je mogu pronaći. Prema njihovom istraživanju, ljudi su se prilagodili mogućnosti da informacije kasnije ponovo pronađu. Kod vještačke inteligencije situacija je složenija jer ona ne pomaže samo u pronalaženju podataka, već može obaviti i dio njihove obrade.

To znači da učenik mora aktivno učestvovati u učenju. Nije dovoljno samo dobiti tačan odgovor; važno je razumjeti kako se do njega dolazi.

Šta pokazuju istraživanja

Istraživanje Kestina i saradnika (2025) pokazuje da vještačka inteligencija ne mora štetiti obrazovanju, nego ga, ako je pedagoški osmišljena i svrsishodno korištena, može i unaprijediti. Na uzorku od 194 studenta s Harvarda uporedili su posebno osmišljenog AI tutora s klasičnim aktivnim učenjem u učionici. Studenti koji su učili uz AI tutora postigli su bolje rezultate i za to im je trebalo manje vremena. Za razliku od običnog chatbota, ovaj tutor je bio izgrađen na principima efikasnog poučavanja: umjesto gotovih odgovora davao je postepene smjernice i podsticao studente da sami razmišljaju. To potvrđuje ranije izloženu razliku između alata i suštine učenja, jer alat koristi onda kada podržava razumijevanje, a ne kada ga zamjenjuje.

Ključ je u dizajnu: tutor nije servirao gotove odgovore, nego je podsticao studente da sami razmišljaju, prilagođavao objašnjenja njihovom nivou i davao brzu povratnu informaciju. Dakle, snaga AI-ja nije u brzom dolaženju do informacija, nego u podršci aktivnom i individualizovanom učenju. Bitno je razlikovati AI kao prečicu do odgovora i AI kao alat koji pomaže da stvarno razumijemo gradivo.

Prvi eksperimentalni podaci o AI to potvrđuju, ali s važnom nijansom. Bastani i saradnici (2025) proveli su terenski eksperiment sa skoro hiljadu srednjoškolaca na časovima matematike. Učenici koji su koristili standardni GPT-4 bolje su rješavali zadatke dok su ga imali, ali kad im je pristup ukinut, na ispitu su bili za 17% slabiji od učenika koji ga nikad nisu koristili. Autori zaključuju da neograničen pristup GPT-4 može štetiti obrazovnim ishodima. Verzija sa ugrađenim zaštitama, koja je učenika usmjeravala umjesto da rješava zadatak umjesto njega, tu je štetu uglavnom ublažila.

Ovo istraživanje u radu ima ulogu korektiva: nakon Kestinovog nalaza ono pokazuje da AI sam po sebi ne garantuje bolje učenje. Za mene je najvažnije to što ovaj eksperiment razdvaja rezultat od znanja. Učenici s običnim GPT-om izgledali su uspješno, a pravo stanje se vidjelo tek kad im je alat oduzet. To potvrđuje ono od čega sam krenula: alat može poboljšati uradak, ali učenje i dalje traži vlastiti napor, i upravo taj napor zaštićena verzija čuva. Zato mi se čini da pitanje nije je li AI dobar ili loš za učenje, nego šta alat radi umjesto učenika, a šta ostavlja njemu. Tu se vidi i zašto je uloga nastavnika sve važnija, jer neko mora procijeniti šta učenik zaista zna kad alata nema.

Kosmyna i saradnici (2025) podijelili su 54 učesnika u tri grupe: jedna je pisala eseje uz jezički model, druga uz pretraživač, a treća bez ikakvih alata. Mjerenjem moždane aktivnosti (EEG) utvrđeno je da su učesnici bez alata imali najintenzivniju i najširе raspoređenu komunikaciju među dijelovima mozga, oni s pretraživačem umjerenu, a korisnici jezičkog modela najslabiju. Učesnici koji su koristili jezički model imali su i slabiji osjećaj autorstva nad vlastitim esejem. Budući da je riječ o preprintu s relativno malim brojem učesnika, rezultate treba tumačiti oprezno. Ipak, oni se uklapaju u ranije nalaze i otvaraju važno pitanje: koliko učenik zaista učestvuje u radu koji nastaje uz pomoć vještačke inteligencije, odnosno ostaje li mu napor koji učenje zahtijeva.

Kada uradak više nije dokaz učenja

Zato je razlika između suštine i alata praktično pitanje. Ako vještačku inteligenciju shvatimo kao promjenu suštine učenja, napustit ćemo ono što o učenju znamo. Ako je shvatimo samo kao još jedan alat, previdjet ćemo da ona potkopava ono što smo koristili kao dokaz učenja: domaći zadatak, seminarski rad, esej. To se vidi već u istraživanjima koja sam navela. Učenici koji su radili uz običan GPT postizali su dobre rezultate dok su ga imali, ali se stvarno znanje pokazalo tek kad im je alat oduzet, a učesnici koji su pisali uz jezički model imali su slabiju moždanu povezanost i slabiji osjećaj autorstva nad vlastitim esejem. Uradak je postojao, ali mentalnog napora koji bi trebao stajati iza njega bilo je manje.

Domaći zadatak, seminarski rad i esej oduvijek su bili posredni dokaz: pretpostavljalo se da ih je učenik sam napisao, pa da gotov rad pokazuje šta zna. Ta pretpostavka više ne stoji, jer isti rad danas može nastati za nekoliko sekundi, bez ikakvog razumijevanja. Suština učenja ostaje ista, ali više ne možemo biti sigurni da naši zadaci i ocjene zaista mjere ono što bismo željeli da mjere. UNESCO-ove smjernice (2023) u tom pogledu predlažu pristup u kojem čovjek zadržava kontrolu, prilagođen uzrastu, uz etičku validaciju, pedagoški osmišljenu upotrebu i zaštitu privatnosti podataka.

Šta ostaje nastavniku

Šta onda ostaje nastavniku kad znanje više nije oskudno? Freire (1970) je kritikovao „bankarski“ model obrazovanja, u kojem je znanje „dar koji dijele oni koji sebe smatraju znalcima“, a učenik prima, arhivira i pohranjuje ono što mu se daje. Ako učenik objašnjenje danas dobije u sekundi, nastavnik koji samo prenosi informacije zaista gubi smisao. Zbog toga mislim da se uloga nastavnika sve više usmjerava na ono što učeniku nije lako pružiti samo pomoću tehnologije.

Nastavnik treba prepoznati šta učenik već razumije, gdje griješi i kakva mu je pomoć potrebna da bi napredovao. To se može povezati s Vygotskijevom zonom narednog razvoja (1978), koja naglašava razliku između onoga što učenik može uraditi samostalno i onoga što može postići uz odgovarajuću pomoć. Važna je i povratna informacija. Hattie i Timperley (2007) ističu da ona može značajno utjecati na učenje, ali da njen učinak zavisi od vrste povratne informacije i načina na koji se daje.

Treća važna uloga nastavnika jeste da učenike nauči kako provjeravati odgovore koje daje vještačka inteligencija. Bastani i saradnici (2025) upozoravaju na mogućnost grešaka u odgovorima generativne AI. Po mom mišljenju, tu nije dovoljno stati na provjeravanju. Učenici trebaju razviti kritički odnos prema svemu što im se nudi, bilo da dolazi od modela, s interneta ili iz udžbenika: pitati ko to tvrdi, na čemu se temelji i zašto nam zvuči uvjerljivo.

> **Modeli griješe istim samouvjerenim tonom kojim govore tačno, pa uvjerljivost nije dokaz tačnosti.** Takav odnos prema znanju ne stječe se primanjem gotovih odgovora, nego u radu s nastavnikom koji traži obrazloženje i pokazuje kako se argumentirano sumnja.

Veća dostupnost znanja mijenja i ulogu nastavnika. Prema Miau i Cukurovoj (2024), AI mijenja tradicionalni odnos između nastavnika i učenika, jer postaje dodatni učesnik u obrazovnom procesu. Nastavnik tako više nije samo prenosilac informacija, nego vodič i mentor koji učenike usmjerava. Njegov zadatak je da ih nauči kako kritički procjenjivati sadržaj koji generiše AI,

prepoznati greške i odgovorno koristiti nove tehnologije. U istom duhu, OECD (2025) naglašava da je potrebno preispitati obrazovne ciljeve i kompetencije koje učenici trebaju razvijati u svijetu napredne vještačke inteligencije. Nastavnik, dakle, ne gubi na značaju zbog lakše dostupnosti informacija, nego mu se uloga mijenja: umjesto reprodukcije znanja, u prvi plan dolaze kritičko mišljenje, samostalno prosuđivanje i primjena znanja u različitim situacijama.

Učenje koje se ne može preuzeti

Vještačka inteligencija, dakle, ne mijenja ono što učenje jeste, nego ono što se može dobiti bez učenja.

Informacije, gotovi tekstovi i tačni odgovori danas su dostupni u sekundi, ali razumijevanje i sposobnost da se znanje primijeni ne mogu se preuzeti, nego se grade. Zato nastavnik u takvom svijetu ne postaje suvišan. Njegova uloga je da učeniku pomogne da od informacija izgradi razumijevanje, a zatim da to razumijevanje i dalje koristi: da ga prenese u nove i drugačije okolnosti, primijeni na problem kakav ranije nije vidio i procijeni kada ono što zna vrijedi, a kada ne. Tek tada možemo reći da je učenje stvarno nastupilo, a ne samo da je zadatak urađen.

Literatura

Bastani, H., Bastani, O., Sungu, A., Ge, H., Kabakcı, Ö., & Mariman, R. (2025). Generative AI without guardrails can harm learning: Evidence from high school mathematics. *Proceedings of the National Academy of Sciences, 122* (26), Article e2422633122. https://doi.org/10.1073/pnas.2422633122

Freire, P. (1970). *Pedagogy of the Oppressed* (prev. M. B. Ramos). Poglavlje 2. Link

Hattie, J., & Timperley, H. (2007). The power of feedback. *Review of Educational Research, 77*(1), 81–112. https://journals.sagepub.com/doi/10.3102/003465430298487

Kestin, G., Miller, K., Klales, A., Milbourne, T., & Ponti, G. (2025). AI tutoring outperforms in-class active learning: An RCT introducing a novel research-based design in an authentic educational setting. *Scientific Reports, 15*,

Article 17458.

Kosmyna, N., Hauptmann, E., Yuan, Y. T., Situ, J., Liao, X.-H., Beresnitzky, A. V., Braunstein, I., & Maes, P. (2025). Your brain on ChatGPT: Accumulation of cognitive debt when using an AI assistant for essay writing task. arXiv:2506.08872

Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. UNESCO. https://unesdoc.unesco.org/ark:/48223/pf0000386693

Sparrow, B., Liu, J., & Wegner, D. M. (2011). Google effects on memory: Cognitive consequences of having information at our fingertips. *Science, 333*(6043), 776–778. https://doi.org/10.1126/science.1207745

Aktivnosti se realizuju u okviru projekta Dijalog za budućnost 3 – #DFF3, kojeg provode UNDP Bosnia and Herzegovina, UNICEF Bosna i Hercegovina i UNESCO u saradnji sa Rezidentnom koordinatoricom United Nations in BiH, te u partnerstvu s Predsjedništvom Bosne i Hercegovine i Ministarstvom civilnih poslova Bosne i Hercegovine. Projekt finansira United Nations Peacebuilding (#PBF).

#DFF3 #dijalogzabudućnost3 #dialogueforthefuture3 #PBF #ZajednicaNastavnika

Collections

Objava