Učenje poučavanjem i konceptualno razumijevanje staničnog disanja kod srednjoškolaca

Josip Cvitan
Poslijediplomski sveučilišni studij Istraživanje u edukaciji u području prirodnih i tehničkih znanosti – usmjerenje Biologija
Prirodoslovno-matematički fakultet Sveučilišta u Splitu
Split, Hrvatska
josipcvitan@yahoo.it

***Sažetak*—Veliki jezični modeli (engl. *large language models*, LLM) postali su svakodnevni alat učenika, no najčešće se koriste pasivno, kao izvor gotovih odgovora. Ovaj rad razmatra obrnutu ulogu: LLM u ulozi učenika kojega učenik poučava, u okviru metode učenja poučavanjem (engl. *learning by teaching*, LbT). Teorijski okvir čine generativno učenje i LbT, čiji se učinci pripisuju objašnjavanju, izgradnji znanja i učinku štićenika. Rad prikazuje razvoj od poučljivih agenata do LLM-ova, prva istraživanja poučavanja chatbotova te ograničenja LLM-a u ulozi učenika, poput simuliranog razumijevanja, sklonosti slaganju s korisnikom i halucinacija. Kao biološki kontekst odabrano je stanično disanje, apstraktan i višerazinski koncept uz koji se vežu postojane miskoncepcije, a njihovo se ispravljanje razmatra u okviru teorije konceptualne promjene. U istraživanju će se koristiti agent koji oponaša učenika s unaprijed zadanim miskoncepcijama i svoju predodžbu mijenja tek kad mu učenik objasni uzročno-posljedične veze. Predlaže se kvazieksperimentalno istraživanje s učenicima trećih razreda gimnazije u tri skupine: učenici poučavaju LLM u ulozi učenika, poučavaju vršnjaka ili uče bez poučavanja. Ishodi su konceptualno razumijevanje i prisutnost miskoncepcija, mjereni dvorazinskim dijagnostičkim testom, te kvaliteta učeničkih objašnjenja, koja će se analizirati prema kategorijama izgradnje i prenošenja znanja. Očekuje se da će rad doprinijeti razumijevanju načina na koje se LLM-ovi mogu svrhovito uključiti u nastavu biologije.**

Ključne riječi—učenje poučavanjem, veliki jezični modeli, poučljivi agenti, stanično disanje, konceptualno razumijevanje, konceptualna promjena, miskoncepcije

I. Uvod

Zadnjih nekoliko desetljeća, a posebno od 2022. godine, kada je pušten ChatGPT, svjedočimo snažnom razvoju i korištenju umjetne inteligencije (UI) u raznim, ako ne i u većini područja djelovanja ljudskog društva [1]. Pritom ni obrazovanje nije izuzetak [2]. Ipak, polje edukacije predstavlja određene specifičnosti, jer se UI ne koristi samo od strane stručnjaka i edukatora, već uvelike i od strane studenata i učenika, koji samostalno i bez nadzora primjenjuju različite UI alate [3]. Izvanredne sposobnosti velikih jezičnih modela (engl. *large language models*, LLM) da obavljaju složene zadatke u području obrazovanja izazivaju podijeljene reakcije među odgojno-obrazovnim djelatnicima, budući da se čini kako ovaj napredak u UI-ju revolucionarno mijenja postojeću obrazovnu praksu [4]. S obzirom na to da učenici i studenti danas imaju izravan pristup sofisticiranim UI alatima, pitanje više nije hoće li UI biti dio obrazovanja, nego kako će njezina primjena utjecati na procese učenja i razumijevanja.

Iako su potencijali UI-ja u obrazovanju veliki, nedostatak jasnih pedagoških smjernica rezultira njezinom površnom i nekontroliranom primjenom, što otvara pitanje kako takvu tehnologiju usmjeriti prema metodama koje potiču aktivno i generativno učenje. Primjećuje se da učenici sve češće koriste ChatGPT kako bi zaobišli istraživački dio zadatka [3], [5], [6]. Umjesto da samostalno traže, analiziraju i biraju informacije, učenici se izravno obraćaju chatu s konkretnim pitanjima te, bez kritičkog razmatranja, prepisuju dobiveni odgovor. Aktivnost koja je ranije podrazumijevala proces istraživanja, selekcije izvora i oblikovanja vlastitog zaključka sada se sve češće svodi na brzo dobivanje gotovog rješenja. Prešli smo od „istraži na internetu" do „pitaj chat". S obzirom na navedeno, u ovome radu razmatra se okvir primjene UI-ja koji bi učenicima mogao biti koristan bez kompromitiranja procesa učenja, a istodobno bi ga mogao učiniti učinkovitijim i dubljim. Umjesto uobičajene interakcije u kojoj učenik LLM-u postavlja pitanja i prima gotove odgovore, predlaže se okvir u kojem LLM preuzima ulogu učenika, dok učenik djeluje kao tutor koji mu objašnjava gradivo. Takav pristup polazi od konstruktivističke teorije učenja i principa učenja poučavanjem (engl. *learning by teaching*, LbT), prema kojima proces objašnjavanja gradiva drugome može potaknuti učenika na aktivno obnavljanje, strukturiranje i verbalizaciju vlastitog znanja. Stoga rad predlaže istraživanje o tome može li takva organizacija interakcije doprinijeti dubljem razumijevanju gradiva te omogućiti učeniku prepoznavanje praznina u vlastitom znanju.

Stanično disanje odabrano je kao primjer gradiva jer predstavlja višeslojni biološki proces koji zahtijeva razumijevanje na različitim razinama organizacije živoga. Ono obuhvaća molekularnu razinu, na kojoj se razgrađuju organske molekule i oslobađa energija, staničnu razinu povezanu s radom mitohondrija, fiziološku razinu koja uključuje opskrbu stanica kisikom i hranjivim tvarima, kao i ekološku razinu koja povezuje disanje s tokovima energije i tvari u ekosustavima. Zbog te složenosti stanično disanje može biti izazovno za učenike te je moguće da kod njih dovodi do djelomičnog razumijevanja ili postojanih miskoncepcija. Iz tog razloga ono predstavlja prikladan primjer za istraživanje LbT-a uz potporu LLM-a.

Cilj je rada teorijski utemeljiti i predložiti istraživanje o tome kako poučavanje LLM-a u ulozi učenika utječe na konceptualno razumijevanje staničnog disanja kod srednjoškolaca te kako učenici prihvaćaju i koriste model u toj ulozi. Nakon uvoda slijedi teorijski okvir LbT-a (II), pregled uloge LLM-ova kao učenika (III), biološki kontekst staničnog disanja (IV), plan istraživanja (V) i zaključak (VI).

II. Učenje poučavanjem kao oblik generativnog učenja

A. Generativno učenje

Teorijski okvir rada čine generativno učenje i LbT, pristupi koji naglašavaju aktivnu obradu znanja i stvaranje smislenih veza među konceptima. Generativno učenje, koje je središnji pojam konstruktivističke tradicije, temelji se na pretpostavci da učenici aktivno stvaraju značenje povezivanjem novih informacija s postojećim znanjem [7], [8]. Razumijevanje i trajno učenje, dakle, rezultat su procesa stvaranja odnosa među konceptima i između novog i postojećeg znanja [7]. U tom procesu, kako navodi Wittrock [7], ključnu ulogu imaju pažnja, elaboracija i aktivacija prethodnog znanja, koji omogućuju učeniku da rekonstruira vlastite mentalne modele. Stvaranje značenja prema tome zahtijeva aktivni napor učenika i svjesno povezivanje novih informacija s postojećim kognitivnim strukturama. Takav proces omogućuje dublje razumijevanje prirodoslovnih koncepata i stoga se generativni pristup pokazuje iznimno prikladnim za nastavu biologije i srodnih područja [8].

Da bi u primjeni generativnih pristupa učenju bili što uspješniji, poželjno je da se učenike potiče na korištenje generativnih strategija učenja, odnosno aktivnosti koje od učenika zahtijevaju da proizvedu smisleni sadržaj koji nadilazi informacije instruktora, te da u istom procesu aktiviraju prethodno znanje povezujući ga s novim informacijama i stvarajući vlastite reprezentacije [9], [10].

Kako bi se razumjelo zašto određene aktivnosti učenja mogu poticati dublju obradu gradiva, korisno je osvrnuti se na teorijske modele koji objašnjavaju kognitivne procese i razinu angažiranosti učenika. Prema Fiorelli, učinci različitih aktivnosti učenja mogu se promatrati kroz dva okvira: model *select–organize–integrate* (SOI), koji objašnjava kognitivne procese odabira, organiziranja i integracije informacija, te model *interactive–constructive–active–passive* (ICAP), koji razlikuje razine angažiranosti učenika u procesu učenja [11], [12]. Oba pristupa naglašavaju važnost aktivnosti koje potiču stvaranje značenja i razumijevanje, osobito u učenju složenih konceptualnih sadržaja poput prirodoslovnih i matematičkih fenomena [12]. Fiorella i Mayer [13] operacionalizirali su koncept generativnog učenja kroz osam strategija koje potiču aktivno stvaranje značenja: sažimanje, mapiranje, crtanje, zamišljanje, samoprovjeravanje, samoobjašnjavanje, poučavanje drugih i izvođenje pokreta (engl. *enacting*). Među navedenim strategijama u središtu ovoga rada nalazi se strategija LbT-a.

B. Učenje poučavanjem: faze i mehanizmi

Učenje poučavanjem pedagoški je pristup u kojem učenik preuzima ulogu nastavnika (tutora) i, objašnjavajući sadržaj drugome (štiću), produbljuje vlastito razumijevanje. Metoda se oslanja na generativnu teoriju učenja jer od tutora zahtijeva aktivno konstruiranje značenja i povezivanje novih informacija s postojećim znanjem [9], [14]. U svojim klasičnim istraživanjima Bargh i Schul [15] pokazali su da kognitivne koristi poučavanja ne nastaju samo tijekom samog čina poučavanja, već i u fazama koje mu prethode i slijede. Razlikuju tri faze: pripremu, u kojoj učenik proučava gradivo s namjerom da ga objasni drugome; samo poučavanje, u kojem sadržaj objašnjava; te interakciju sa štićenikom, u kojoj odgovara na pitanja i pruža povratne informacije. Tu podjelu razrađuju kasnija istraživanja koja učinke pojedinih faza ispituju odvojeno [9], [16]–[18].

Pojedine faze ne pridonose učenju jednako. Već sama namjera da se nešto pouči može poboljšati učenje, no učinci su veći i trajniji kad priprema završi stvarnim poučavanjem [17]–[19]. Metoda se pokazuje korisnom i pri poučavanju bez interakcije, primjerice kad učenici objašnjavaju gradivo pred kamerom zamišljenom vršnjaku [20], ali interakcija sa štićenikom donosi dodatne prilike za učenje [21]. Ta se interakcija ne mora odvijati s drugim učenikom: razvijeni su i pristupi u kojima tutori poučavaju virtualne agente [22]–[24]. Pritom je posebno zanimljivo kako se u taj okvir uklapa poučavanje LLM-a, s kojim se, za razliku od ranijih agenata, razgovara u prirodnom jeziku.

Koristi poučavanja mogu se pripisati trima skupinama mehanizama. Prvi je objašnjavanje: da bi sadržaj prenio drugome, tutor mora reorganizirati vlastito znanje, povezati pojmove i zaključivati, pri čemu uočava praznine u vlastitom razumijevanju [25]–[28]. Drugi je interakcija: pitanja i nesporazumi štićenika, osobito pitanja koja traže objašnjenje „zašto” i „kako”, potiču tutora da preispita i dopuni svoje objašnjenje [21]. Treći je motivacijski i opisan je kao učinak štićenika (engl. *protégé effect*).

Chase i sur. [29] pokazali su da učenici osmog razreda koji uče biologiju (regulaciju tjelesne temperature) ulažu više truda kad uče kako bi poučili virtualnog agenta nego kad uče za sebe. Autori to dijelom pripisuju osjećaju odgovornosti za štićenika i svojevrsnom zaštitnom odmaku (engl. *ego-protective buffer*): neuspjeh se ne pripisuje učenikovim sposobnostima, nego lošem poučavanju ili dijelom agentu, pa učenik lakše priznaje pogreške i radi na njihovu ispravljanju. Učinak štićenika važan je za ovaj rad jer pokazuje da motivacijske koristi poučavanja ne zahtijevaju stvarnu osobu u ulozi učenika.

Istraživanja ipak pokazuju da učenici koji poučavaju ne iskorištavaju uvijek puni potencijal svoje uloge [21]. Roscoe i Chi [21] razlikuju dva načina objašnjavanja. Pri prenošenju znanja (engl. *knowledge telling*) tutor prepričava činjenice i opisuje postupke bez dublje elaboracije, što može pridonijeti pamćenju, ali ne i razumijevanju. Pri izgradnji znanja (engl. *knowledge building*) tutor povezuje pojmove, izvodi nove zaključke i nadzire vlastito razumijevanje. Učinkovitost LbT-a stoga ovisi o tome u kojoj mjeri tutor gradi znanje [21], [30], a izgradnju znanja ponajviše potiču upravo pitanja i pogreške štićenika [21]. Za poučavanje LLM-a iz toga proizlazi ključno pitanje: može li model u ulozi učenika postavljati takva pitanja i činiti takve pogreške da potakne izgradnju, a ne samo prenošenje znanja?

C. Pregled istraživanja o učinkovitosti učenja poučavanjem

Empirijski nalazi o LbT-u uglavnom su pozitivni, ali pokazuju i da učinak ovisi o uvjetima u kojima se metoda provodi. Već su rani radovi pokazali da poučavanje koristi samom tutoru. Annis [31] ističe važnost samog čina poučavanja, a Bargh i Schul [15] važnost pripreme za poučavanje. Benware i Deci [32] pokazali su da učenje s namjerom poučavanja povećava unutarnju motivaciju i konceptualno razumijevanje. Pozitivne učinke metode potvrđuju i noviji pregled Durana [30] te metaanaliza Kobayashija [19].

Velik dio istraživanja bavi se pitanjem koji dio metode donosi korist. Fiorella i Mayer [17], [18] pokazali su da sama priprema za poučavanje poboljšava razumijevanje na neposrednom testu, ali da stvarno poučavanje daje trajnije učinke, vidljive i na odgođenom testu. Metaanaliza Kobayashija [19], koja obuhvaća 28 istraživanja, pokazala je pozitivan učinak same pripreme za poučavanje ($g = 0,35$) i veći učinak stvarnog poučavanja ($g = 0,56$), osobito kad je poučavanje uključivalo interakciju. Učinak ovisi i o načinu

poučavanja: Fiorella i Kuhlmann [33] pokazali su da izrada crteža tijekom poučavanja dodatno poboljšava učenje.

Posebnu ulogu ima interakcija sa štićenikom. Webb [34] ističe da objašnjavanje drugima nudi više prilika za učenje nego objašnjavanje samome sebi, jer slušatelj može uočiti praznine i nedosljednosti te tražiti pojašnjenje. Da bi ih razriješio, onaj koji objašnjava mora tražiti nove informacije i graditi dublje razine znanja. U preglednom radu Roscoe i Chi [21] pokazuju da tutori najviše uče kad grade znanje umjesto da ga samo prenose, i kad štićenik postavlja pitanja koja to potiču. Mnogi tutori ipak ostaju na razini prenošenja znanja [21].

Za ovaj rad važni su i nalazi iz biologije. U već spomenutom istraživanju Chase i sur. [29] učenici koji su poučavali virtualnog agenta bolje su riješili zahtjevna pitanja koja traže povezivanje uzročnih lanaca, a učinak je bio najveći kod slabijih učenika. Malik Pelumi i sur. [35] istraživali su LbT sa 60 srednjoškolaca koji su učili ekologiju populacija. Učenike su podijelili u četiri skupine: jedna je slušala samo predavanje, druga se pripremala za poučavanje, treća je poučavala bez interakcije, a četvrta s interakcijom. Najbolje rezultate, i na neposrednom i na tjedan dana odgođenom testu, postigli su učenici koji su poučavali uz interakciju, što potvrđuje važnost interakcije opisanu iznad. Sama priprema za poučavanje nije se značajno razlikovala od predavanja. Oba istraživanja provedena su, međutim, na malim uzorcima i s kratkim razdobljem praćenja, a nijedno nije bilo usmjereno na miskoncepcije niti je ispitivalo poučavanje LLM-a. To upućuje na moguću prazninu u istraživanjima kojoj ovaj rad nastoji pridonijeti.

III. Veliki jezični model kao učenik

Kako je prethodno prikazano, LbT može predstavljati učinkoviti oblik generativnog učenja koji se oslanja na objašnjavanje i refleksiju. Pojava LLM-ova otvara mogućnost da ih učenici tijekom učenja koriste kao kognitivnog partnera, bilo kao „učenika" kojem objašnjavaju sadržaj [36]–[38], bilo kao izvor brze povratne informacije [39]. Pritom je presudno kako je model postavljen: neograničen pristup generativnoj UI može naštetiti učenju jer učenici model koriste kao zamjenu za vlastiti rad, dok model postavljen da vodi učenika umjesto da mu daje gotova rješenja taj negativni učinak uglavnom uklanja [40]. Integracija UI alata mora biti didaktički usmjerena: sustavni pregled istraživanja o UI-ju u visokom obrazovanju upozorava da sama tehnologija bez jasnog pedagoškog dizajna ne vodi nužno do boljih ishoda [41].

A. *Uporaba umjetne inteligencije u obrazovanju: prednosti i rizici*

Veliki jezični model ChatGPT, kao jedan od najpoznatijih modela UI-ja, procesuira prirodni jezik te pomoću tehnika dubokog učenja generira uvjerljive i stilski dotjerane odgovore [42]. Upravo zbog toga postao je iznimno popularan, kako među stručnjacima, tako i među širom populacijom, uključujući studente i učenike, koji u ChatGPT-ju pronalaze alat za ostvarivanje vlastitih ciljeva, neki od kojih mogu biti više ili manje u skladu s didaktičko-pedagoškim standardima, pa čak i u suprotnosti s njima.

Uporaba UI-ja među učenicima i studentima brzo raste. U Ujedinjenom Kraljevstvu udio studenata koji koriste generativnu UI za ispitne zadatke porastao je s 53 % 2024. na 88 % 2025. godine [43], a u SAD-u se udio tinejdžera koji ChatGPT koriste za školske zadatke udvostručio, s 13 % na 26 % [44]. U Hrvatskoj velik dio učenika osnovnih i srednjih škola koristi alate temeljene na UI-ju, posebice chatbotove, za traženje informacija, objašnjavanje gradiva i izradu školskih zadataka [45], a Črček i Patekar [46] prijavljuju da je više od polovice od 201 ispitanog studenta hrvatskih sveučilišta koristilo ChatGPT pri izradi pisanih zadataka, najčešće za generiranje ideja, ali i za sažimanje, parafraziranje te pisanje dijelova zadataka. Studenti UI chatbotove najčešće koriste za dobivanje povratne informacije i potporu u učenju, za pretraživanje informacija i izvora te kao pomoć pri izradi zadataka [47], [48]. Takva uporaba nije nužno zloupotreba: učenici UI najčešće koriste za pretraživanje i objašnjavanje pojmova, a pisanje cijelih radova uglavnom smatraju neprihvatljivim [44], [49].

Prema Kasneci i sur. [5], korištenje LLM-ova može pomoći učenicima u razvoju vještina pisanja, čitanja i kritičkog razmišljanja, kao i u boljem kontekstualiziranju i pamćenju sadržaja te u razvijanju sposobnosti rješavanja problema. Šira obrazovna literatura opisuje i primjenu UI-ja u tutorstvu, vrednovanju, izradi nastavnih sadržaja i personaliziranom učenju [50], [51]. Kao prednosti ističu se trenutačna povratna informacija i lakši pristup izvorima [47], mogućnost personaliziranog učenja i vođenja korak po korak putem inteligentnih tutorskih sustava [50] te bolje iskustvo učenja kada UI nadopunjuje rad nastavnika [50].

No, iako ovi modeli nude zanimljive mogućnosti, u kontekstu nekritičnog ili neetičnog korištenja mogu proizvesti i negativne učinke. Češća uporaba ChatGPT-a povezana je s češćim plagiranjem [52], a učenici koji ga koriste kao zamjenu za vlastiti rad kasnije postižu slabije rezultate [40]. Upozorava se i na rizike za akademsku čestitost [47], na netočne informacije i „halucinacije", pristranost te etička pitanja i pitanja privatnosti [5], [53], na prekomjerno oslanjanje na UI koje može oslabiti kritičko i kreativno mišljenje [47], [48] te na digitalni jaz i nejednak pristup tehnologiji [51]. U kontekstu zdravstvenog obrazovanja Sallam [54] ističe i probleme transparentnosti, autorskih prava i legalnosti, nedostatka originalnosti, pogrešnog citiranja i ranjivosti u području kibernetičke sigurnosti te rizik širenja dezinformacija (infodemije).

B. *Od pedagoških i poučljivih agenata do velikih jezičnih modela*

Istraživanja virtualnih agenata u obrazovanju razlikuju dvije temeljne uloge. Pedagoški agenti preuzimaju ulogu tutora: učeniku daju savjete, objašnjenja i povratne informacije. Poučljivi agenti (engl. teachable agents) imaju obrnutu ulogu: učenik ih poučava, a agent zaključuje na temelju onoga što je naučio [29], [55]. Najpoznatiji primjer je Betty's Brain, u kojem učenici agenta poučavaju izradom uzročnih koncept-mapa o prirodnim procesima [55]. U istraživanjima s poučljivim agentima učenici najčešće ne vode prirodan razgovor, nego sudjeluju u strukturiranim aktivnostima poput izrade koncept-mapa ili odgovaranja na pitanja zatvorenog tipa [23], [56], a okruženja im pritom pružaju metakognitivnu potporu i izričitu povratnu informaciju [24], [57], [58].

Veliki jezični modeli mogu preuzeti obje uloge, ali u prirodnom jeziku. U ulozi tutora model učeniku pruža vođenje i povratnu informaciju. Bastani i sur. [40] pokazali su da je pritom presudno kako je model postavljen: model koji učeniku daje smjernice umjesto gotovih rješenja podržava učenje, a neograničen pristup mu može naštetiti. U ulozi učenika model preuzima mjesto poučljivog agenta, pa se razgovor s njim približava poučavanju stvarne osobe. Mollick i Mollick [59] opisuju praktičnu inačicu te uloge, „UI-student": model objašnjava zadani pojam i navodi primjere, a učenik procjenjuje objašnjenje, uočava pogreške i propuste te ih

modelu objašnjava. Jin i sur. [38] idu korak dalje i modelu unaprijed zadaju miskoncepcije i praznine u znanju, tako da učenik mora poučavati, a ne samo ispravljati.

Ovaj rad usmjeren je na drugu ulogu: LLM u ulozi učenika kojega učenik poučava. U objema ulogama ključno je da učenik kritički procjenjuje ono što model proizvede, odnosno da čovjek ostane „u petlji" [47], [59].

C. Istraživanja poučavanja chatbotova i velikih jezičnih modela

Već postoje pionirska istraživanja primjene chatbotova i ChatGPT-a u metodi LbT-a, s obećavajućim rezultatima. Sabnis i Nagashima [36] u konferencijskom su radu na malom uzorku studenata usporedili poučavanje chatbota s rješavanjem problemskih zadataka iz udžbenika, a njihovi rezultati upućuju na to da chatbotovi mogu poslužiti kao „virtualni učenici". Slično tome, Chen i sur. [37] pokazali su da poučavanje ChatGPT-a programiranju može poboljšati ishode učenja, osobito samoregulirano učenje i samoučinkovitost. Autori zaključuju da interakcija s modelom u ulozi poučavanog agenta može potaknuti mehanizme karakteristične za LbT. Slični su nalazi dobiveni i u glazbenoj teoriji, gdje su studenti koji su poučavali LLM-agenta postigli bolje rezultate od onih koji su učili samostalno i prijavili manje kognitivno opterećenje [60]. Prema dostupnoj literaturi, poučavanje virtualnog agenta u biologiji dosad je istraživano samo s ranijim poučljivim agentima, poput onog u istraživanju Chase i sur. [29], ali ne i s LLM-ovima.

Otvoreno je stoga pitanje mogu li se slični učinci postići i u biologiji, u kojoj učenici moraju razumjeti apstraktne procese i uzročne veze, primjerice u staničnom disanju, a pritom imaju postojane miskoncepcije. Za takvu primjenu nije dovoljno samo razgovarati s modelom: važno je kako je model postavljen u ulogu učenika. Upravo su to istražili Jin i sur. [38], koji su razvili LLM-štićenika za učenje algoritama kojemu se mogu zadati miskoncepcije i praznine u znanju, a koji tutoru postavlja pitanja „zašto" i „kako". U istraživanju s 40 početnika takva su pitanja dovela do razgovora bogatijih znanjem.

D. Ograničenja velikih jezičnih modela u ulozi učenika

Iako LLM može u znatnoj mjeri oponašati dijalog s učenikom, granica između stvarne interakcije i simulirane komunikacije ostaje važna. U stvarnom kontekstu poučavanja učenik često pokazuje nesigurnost, pogrešno razumije objašnjenje ili postavlja nejasna pitanja, čime potiče tutora na dodatno promišljanje i prestrukturiranje vlastitog znanja [21]. Takvu dinamiku teško je u potpunosti reproducirati u razgovoru s modelom koji „razumije" samo na razini predikcije jezika: recentna istraživanja pokazuju da LLM-ovi ne reagiraju na temelju dosljednog semantičkog razumijevanja, nego smisao više simuliraju [61], [62]. Zbog toga postoji i rizik da učenici nekritički prihvate netočne informacije ili da model postane zamjena za njihovu vlastitu kognitivnu obradu. Uloga modela stoga ostaje pomoćna: on može biti potpora generativnim procesima, ali ne i zamjena za stvarnu socijalno-kognitivnu interakciju [5], [41], [63].

Poseban problem jest to što su LLM-ovi po zadanim postavkama skloni stručnim, sigurnim odgovorima. U ulozi štićenika tako preuzimaju kognitivni posao i tutoru ostavljaju malo toga za objasniti [64]. Miller i Bosch [64] pokazali su da sama uloga („ti si početnik") slabo mijenja takvo ponašanje, a da modele najpouzdanije usmjeravaju izričite upute da griješe, primjerice „pogriješi dva ili tri odgovora". Jin i So [65] dodaju da LLM-štićenici bez izričitog nastavnog vodstva ne potiču sustavno izgradnju znanja kod tutora, pa predlažu da se strategija poučavanja agentu zada kao niz unaprijed određenih koraka.

Dva dodatna ograničenja posebno su važna kad model preuzme ulogu učenika. Prvo, LLM-ovi skloni su slaganju s korisnikom (engl. *sycophancy*): odgovore prilagođavaju uvjerenjima korisnika, čak i na račun točnosti [66]. U simuliranom obrazovnom kontekstu točnost modela znatno je padala kad je učenik predložio netočan odgovor [67]. U LbT-u to znači da model može prihvatiti učenikovo pogrešno objašnjenje i tako učvrstiti miskoncepciju umjesto da je dovede u pitanje. Drugo, modeli tijekom duljeg razgovora postupno prestaju slijediti zadane upute [68], pa „učenik" s miskoncepcijama može s vremenom početi odgovarati kao stručnjak.

Konačno, LLM-ovi skloni su halucinacijama, odnosno odgovorima koji zvuče uvjerljivo, ali nisu točni [69]. Do njih dolazi jer model ne pretražuje podatke na kojima je treniran, kako mnogi korisnici pretpostavljaju, nego generira niz riječi koji je u danom kontekstu najvjerojatniji [69], [70]. Kad se odgovor u podacima za treniranje pojavljuje rijetko ili nikako, model će ipak proizvesti odgovor, ali uz malu vjerojatnost da je točan [70], [71].

IV. Konceptualno razumijevanje staničnog disanja

A. Konceptualno razumijevanje i konceptualna promjena

Revidirana Bloomova taksonomija razlikuje nekoliko vrsta znanja [72]. Činjenično znanje obuhvaća osnovne elemente koje učenik mora poznavati da bi se snašao u nekom području, poput pojmova i podataka. Konceptualno znanje odnosi se na međusobne odnose tih elemenata unutar šire strukture, koji im omogućuju da funkcioniraju zajedno. Proceduralno znanje odnosi se na to kako nešto učiniti, odnosno na metode, postupke i kriterije za njihovu primjenu [72]. Na primjeru staničnog disanja, činjenično znanje je poznavanje naziva stadija procesa, poput glikolize i Krebsova ciklusa. Konceptualno razumijevanje uključuje sposobnost da učenik objasni zašto je kisik potreban, odakle potječe energija pohranjena u adenozin-trifosfatu (ATP) i kako je stanično disanje povezano s fotosintezom. U ovom radu konceptualno razumijevanje shvaća se kao sposobnost povezivanja pojmova u smislenu cjelinu, objašnjavanja uzročno-posljedičnih odnosa i primjene znanja u novim situacijama. To odgovara smislenom učenju, u kojem se nove informacije povezuju s postojećim znanjem [73], i konceptualnoj promjeni, u kojoj učenici preispituju i preoblikuju vlastite predodžbe [74]. Poučavanje znanosti trebalo bi se odmaknuti od pukog pamćenja i naglasiti konstruktivističke pristupe koji potiču smisleno konceptualno razumijevanje [75]. Smisleno učenje događa se kada se nova informacija oslanja i povezuje na prethodno stečene koncepte [73], pri čemu učenici trebaju aktivno preispitivati vlastite ideje i stvarati nova značenja [74], [76]. To je osobito važno u temama poput staničnog disanja, gdje mnoge miskoncepcije proizlaze iz zdravorazumskih objašnjenja emergentnih procesa.

Kad učenik već ima pogrešnu predodžbu, do konceptualnog razumijevanja ne dolazi se samo dodavanjem novog znanja. Posner i sur. [77] razlikuju asimilaciju, u kojoj učenik nove pojave objašnjava postojećim pojmovima, i akomodaciju, u kojoj središnje pojmove mora preurediti ili zamijeniti jer pomoću njih ne može razumjeti novu pojavu. Da bi došlo do akomodacije, učenik mora biti nezadovoljan postojećom predodžbom, a nova predodžba mora mu biti razumljiva, od početka uvjerljiva i plodna, odnosno mora otvarati nove mogućnosti objašnjavanja [77]. Vosniadou [78] ističe da učenik nove informacije tumači unutar okvirne teorije

koju gradi od ranog djetinjstva. Pretpostavke te teorije ograničavaju način na koji učenik tumači ono što opaža, a upravo ih je najteže promijeniti. Chi [74] objašnjava zašto su neke miskoncepcije osobito otporne. Učenici procese koji nastaju iz mnoštva istodobnih interakcija tumače kao jednostavne, izravne procese, pa za promjenu nije dovoljno dodati nove činjenice, nego treba promijeniti način na koji učenik shvaća sam proces. Stanično disanje, u kojem se energija oslobađa kroz niz reakcija na molekularnoj razini, a koje učenici često svode na udisanje kisika i izdisanje ugljikova dioksida, tema je u kojoj se takve poteškoće mogu očekivati.

Ni suočavanje s proturječnim podacima samo po sebi ne dovodi do promjene. Chinn i Brewer [79] opisuju sedam načina na koje učenici, ali i znanstvenici, reagiraju na podatke koji proturječe njihovim predodžbama. Samo jedan od njih uključuje stvarnu promjenu teorije, dok se u ostalima podaci zanemaruju, odbacuju ili reinterpretiraju kako bi se postojeća predodžba sačuvala. Za ovaj rad to znači da učeniku nije dovoljno reći da je njegova predodžba pogrešna, nego mu treba ponuditi objašnjenje koje je razumljivo i uvjerljivo. Na tim se uvjetima temelji i pravilo prema kojem agent opisan u potpoglavlju IV.D mijenja svoju predodžbu tek kad mu učenik objasni zašto je pogrešna i ponudi uvjerljivije objašnjenje. Učenik tako preuzima ulogu onoga tko treba potaknuti konceptualnu promjenu, a da bi u tome uspio, mora i sam jasno razumjeti zašto je miskoncepcija pogrešna.

B. Stanično disanje u kurikulumu biologije

Prema Kurikulumu nastavnog predmeta Biologija za osnovne i srednje škole, nastava biologije usmjerena je na razvoj konceptualnog razumijevanja i poticanje znanstvenog načina mišljenja, pri čemu se primjenjuju strategije aktivnoga i istraživačkoga učenja [80]. Kurikulum je organiziran u četiri domene, od kojih je jedna Energija u živome svijetu. Učenici se sa staničnim disanjem prvi put susreću u 7. razredu osnovne škole, u sklopu procesa oslobađanja energije, a u gimnaziji ga detaljno obrađuju u 3. razredu kroz ishode BIO SŠ C.3.1. „Analizira procese kruženja tvari, vezanja i pretvorbi energije na razini stanice povezujući ih s funkcioniranjem organizama” i BIO SŠ C.3.2. „Analizira principe iskorištavanja energije na razini stanice” [80]. Prema prijedlogu godišnjeg izvedbenog kurikuluma, tema obuhvaća iskoristivost hranjivih tvari u aerobnim i anaerobnim procesima te osnovne metaboličke procese na razini stanice, a obrađuje se neposredno nakon fotosinteze [81]. Službeni ishodi formulirani su općenito, pa su za potrebe ovog istraživanja iz njih izvedeni konkretniji ishodi, u skladu s preporukom da se ishodi učenja formuliraju mjerljivim glagolima prema Bloomovoj taksonomiji [82]. Nakon poučavanja staničnog disanja učenik definira stanično disanje kao metabolički proces oslobađanja energije u stanici te razlikuje i objašnjava aerobno i anaerobno disanje, navodeći biološke primjere. Učenik također prikazuje i povezuje glavne stadije aerobnog staničnog disanja (glikolizu, ciklus limunske kiseline i lanac prijenosa elektrona) te objašnjava ulogu kisika, glukoze i mitohondrija u tom procesu. Nadalje, objašnjava važnost staničnog disanja za organizam, osobito za proizvodnju ATP-a, opskrbu stanica energijom i metabolizam, te prepoznaje posljedice njegova poremećaja. Konačno, učenik primjenjuje znanje modeliranjem ili simulacijom procesa te zaključuje kako promjene uvjeta, primjerice smanjen sadržaj kisika, utječu na njegovu učinkovitost.

C. Poteškoće u razumijevanju i miskoncepcije

Stanično disanje posebno je kognitivno zahtjevan koncept jer uključuje procese koji se odvijaju na molekularnoj razini, nevidljivoj golim okom, i koji povezuju biokemijske reakcije s makroskopskim funkcijama organizma i tokovima tvari i energije u ekosustavu [83]. Učenicima je upravo povezivanje tih razina posebno zahtjevno, pa procese često razdvajaju i ne vide veze među njima [83], [84]. Takvi složeni koncepti zahtijevaju pristupe koji potiču aktivnu obradu i integraciju informacija.

Učenici često poistovjećuju disanje sa samim udisanjem zraka ili smatraju da se energija „stvara” u stanici, umjesto da se oslobađa iz kemijskih spojeva [85], [86]. Učenici također smatraju da se udahnuti kisik u disanju izravno pretvara u ugljikov dioksid koji se izdiše [85]. Kisik je, međutim, krajnji primatelj elektrona u lancu prijenosa elektrona i pritom se reducira u vodu, dok ugljikov dioksid nastaje razgradnjom organskih molekula u ciklusu limunske kiseline. Studenti uz to teško prate kamo odlazi tvar tijekom disanja i pritom često zanemaruju plinove [87]. Miskoncepcije o staničnom disanju često nastaju već pri prvom susretu s pojmom, kad se nove informacije tumače kroz svakodnevno iskustvo i zdravorazumska objašnjenja [74], [76]. Mogu ih učvrstiti i nastava i udžbenici, primjerice prikazivanjem fotosinteze i disanja kao suprotnih procesa ili izrazima koji sugeriraju da se disanje odvija izvan stanica [85]. Iz nastavne prakse autora može se dodati da učenici od najranije dobi uče kako udišu kisik i izdišu zrak bogat ugljikovim dioksidom, pa mlađi učenici često odgovaraju da „udišemo kisik, a izdišemo ugljikov dioksid”. Ako se takvo pojednostavljenje kasnije ne poveže sa zbivanjima na razini stanice, lako prelazi u miskoncepciju da se kisik u disanju pretvara u ugljikov dioksid, koju bilježe i istraživanja [85]. Haslam i Treagust [88] ističu da učenici često ne povezuju stanično disanje s fotosintezom, iako se radi o jednoj od temeljnih bioloških veza. Vančugovienė i suradnici [89] pokazali su da većina učenika ostaje na površnim profilima razumijevanja kako fotosinteze tako i staničnog disanja, što potvrđuju i druga istraživanja [88], [90]–[92]. Sve to upućuje na postojanost miskoncepcija, odnosno odstupanja od znanstveno prihvaćenih objašnjenja koja se teško ispravljaju klasičnim poučavanjem.

Istraživanja dosljedno opisuju nekoliko skupina miskoncepcija o staničnom disanju. Najraširenija je poistovjećivanje staničnog disanja s udisanjem i izmjenom plinova: učenici smatraju da se disanje odvija u plućima, a ne u stanicama [86], pa je u istraživanju s učenicima i studentima više od 70 % ispitanika teško razumjelo da se disanje događa u stanicama [85]. Druga skupina odnosi se na energiju: učenici smatraju da se energija u disanju „stvara”, a u jednadžbi disanja energiju često izostavljaju [85]. S time je povezana predodžba o pretvorbi tvari u energiju: kad su objašnjavali gubitak tjelesne masti, 85 % studenata napisalo je da se mast „pretvara u energiju”, a samo je jedan student dao odgovor koji je uključivao stvarne produkte razgradnje [87]. Treća skupina odnosi se na biljke, za koje učenici smatraju da ne dišu, nego samo fotosintetiziraju, ili da dišu samo noću [85], [88]. Učenici također fotosintezu i stanično disanje često shvaćaju kao suprotne procese koji se odvijaju u različito doba dana, a takvu predodžbu dodatno potiču i usporedbe u udžbenicima [85]. Konačno, učenici teško povezuju protok energije i kruženje tvari kroz hranidbene lance, fotosintezu i disanje [84], pri čemu najčešće zanemaruju plinove kao nositelje tvari [87].

D. Poučavanje velikog jezičnog modela kao put do razumijevanja

U tom kontekstu, generativno učenje i LbT predstavljaju prikladne strategije jer potiču učenike na reorganizaciju i verbalizaciju znanja, čime se povećava vjerojatnost dubljeg

razumijevanja. Metoda LbT-a može se primijeniti tako da učenici preuzimaju ulogu nastavnika i objašnjavaju procese poput glikolize, Krebsova ciklusa i oksidativne fosforilacije. Objašnjavanjem tih procesa učenici moraju prepoznati i objasniti uzročno-posljedične odnose između unosa kisika, razgradnje glukoze i sinteze ATP-a, čime aktiviraju ključne generativne procese — odabir, organizaciju i integraciju informacija [13]. Takvo objašnjavanje doprinosi metakognitivnoj refleksiji jer učenici prepoznaju vlastite pogrešne predodžbe i prestrukturiraju ih u skladu s novim razumijevanjem [21].

S obzirom na navedene izazove, logičan je korak istražiti može li LLM u ulozi učenika pridonijeti učinkovitosti ove metode. Kako je pokazano u poglavlju III, takav model može postavljati pitanja, tražiti pojašnjenja i činiti pogreške koje učenik mora ispraviti, ali samo ako je za tu ulogu pažljivo oblikovan [38], [64].

Na temelju navedenog, u ovom radu predlaže se da LLM preuzme ulogu poučljivog agenta posebno oblikovanog za poučavanje staničnog disanja. Agent oponaša učenika trećeg razreda gimnazije koji je stanično disanje već učio, ali ga razumije djelomično i zastupa nekoliko miskoncepcija opisanih u potpoglavlju IV.C, primjerice da se udahnuti kisik u disanju pretvara u ugljikov dioksid, da se energija u stanici stvara te da biljke dišu samo noću. Miskoncepcije su agentu zadane izričitim uputama, jer su se takve upute pokazale pouzdanijima od samog zadavanja uloge početnika [64], a tijekom razgovora agent postavlja pitanja „zašto” i „kako”, koja su u ranijem istraživanju dovela do razgovora bogatijih znanjem [38]. Zadatak učenika je objasniti agentu stanično disanje tako da agent promijeni svoje pogrešne predodžbe. Agent pritom ne prihvaća objašnjenje samo zato što ga učenik tvrdi, nego predodžbu mijenja tek kad učenik objasni uzročno-posljedične veze između razgradnje glukoze, uloge kisika kao krajnjeg primatelja elektrona i sinteze ATP-a. Takvim se pravilom nastoji smanjiti sklonost modela slaganju s korisnikom [66], [67] i potaknuti učenika na izgradnju, a ne samo na prenošenje znanja [21]. Razgovor slijedi unaprijed određene korake [65]: agent najprije iznosi vlastito razumijevanje procesa, zatim postavlja pitanja i iznosi protuprimjere, a na kraju sažima što je naučio, dok učenik provjerava i dopunjuje taj sažetak. Agent će se prije glavnog istraživanja razvijati i provjeravati u nekoliko ciklusa, a njegov je opis dan u potpoglavlju V.C.

Zaključno, stanično disanje primjer je složenog biološkog koncepta koji se može uspješnije poučavati generativnim metodama koje uključuju objašnjavanje, refleksiju i rekonstrukciju znanja. U tom procesu UI može imati značajnu ulogu kao podrška, ali samo ako se koristi unutar jasno definiranog pedagoškog okvira koji učenika zadržava u središtu procesa kao aktivnog konstruktora značenja. Takav pristup može unaprijediti razumijevanje staničnog disanja i otvoriti prostor za istraživanje učinkovitosti poučavanja LLM-a u prirodoslovnom obrazovanju.

V. Plan istraživanja

A. Cilj i istraživačka pitanja

Cilj istraživanja je ispitati kako poučavanje velikog jezičnog modela u ulozi učenika utječe na konceptualno razumijevanje staničnog disanja kod učenika trećeg razreda gimnazije. Iz cilja proizlaze tri istraživačka pitanja. Prvo pitanje je razlikuju li se učenici koji poučavaju agenta, učenici koji poučavaju vršnjaka i učenici koji uče samostalno u konceptualnom razumijevanju staničnog disanja i u broju miskoncepcija, i to neposredno nakon intervencije i nakon nekoliko tjedana. Drugo pitanje je u kojoj mjeri učenička objašnjenja agentu pokazuju izgradnju, a ne samo prenošenje znanja, te razlikuju li se po tome od objašnjenja vršnjacima. Treće pitanje je kakve prednosti i ograničenja rada s agentom uočavaju sami učenici.

Na temelju dosadašnjih istraživanja LbT-a [17], [19], [35] postavljene su dvije hipoteze. Prema prvoj hipotezi, učenici koji poučavaju agenta postići će bolje konceptualno razumijevanje i imati manje miskoncepcija od učenika koji uče samostalno. Prema drugoj hipotezi, isto će vrijediti i za učenike koji poučavaju vršnjaka. Usporedba poučavanja agenta i poučavanja vršnjaka nije postavljena kao hipoteza, jer za nju još nema dovoljno empirijskih podataka, pa će se razmatrati istraživački.

B. Nacrt istraživanja

Istraživanje je zamišljeno kao kvazieksperiment s pretestom, posttestom i odgođenim testom [93]. Skupine čine cijeli razredi, jer nasumično raspoređivanje pojedinih učenika u školi nije izvedivo bez ometanja nastave, a učenici iz istog razreda mogli bi međusobno prenositi iskustva iz različitih uvjeta. Razredi će se, gdje je to moguće, nasumično rasporediti u jedan od triju uvjeta: poučavanje agenta, poučavanje vršnjaka i samostalno učenje. Razlike u početnom znanju među razredima kontrolirat će se pretestom.

Sudionici će biti učenici trećeg razreda gimnazije, jer se stanično disanje prema kurikulumu obrađuje upravo u tom razredu [80]. Područje provedbe, broj škola i broj razreda bit će određeni nakon pilot-istraživanja. Potrebna veličina uzorka odredit će se analizom snage testa [94], uzimajući u obzir to da su učenici grupirani u razrede, što smanjuje stvarnu snagu testa [95].

Istraživanje će se provesti u tri faze. U prvoj fazi razvit će se i provjeriti agent. U drugoj fazi provest će se pilot-istraživanje s manjim brojem učenika, u kojem će se provjeriti agent, instrumenti i trajanje intervencije. Treća faza je glavno istraživanje.

C. Intervencija i razvoj agenta

Sve skupine najprije će imati isti uvodni sat o staničnom disanju i koristiti iste nastavne materijale. Nakon toga učenici u prvoj skupini pripremaju se za poučavanje i poučavaju agenta. Učenici u drugoj skupini rade u parovima i poučavaju jedan drugoga, pri čemu se uloge izmjenjuju. Učenici u kontrolnoj skupini isto vrijeme samostalno uče iz istih materijala. Sve skupine imat će jednako vrijeme na raspolaganju. Okvirno se planiraju dva školska sata, a konačno trajanje odredit će se nakon provedbe pilot-istraživanja.

Agent će se razvijati po načelima istraživanja temeljenog na dizajnu, u kojem se obrazovni alat razvija i provjerava u stvarnim uvjetima u nekoliko ciklusa [96]. Agent oponaša učenika s djelomičnim razumijevanjem i zadanim miskoncepcijama, postavlja pitanja i predodžbu mijenja tek kad mu učenik objasni uzročno-posljedične veze, kako je opisano u potpoglavlju IV.D. Prije rada s učenicima agent će se provjeriti nizom pripremljenih razgovora u kojima „učenik” daje točna, djelomično točna i netočna objašnjenja. Pritom će se pratiti zadržava li agent zadane miskoncepcije, odaje li točne odgovore, prihvaća li netočna objašnjenja i ostaje li u ulozi tijekom duljeg razgovora, jer su to poznati problemi LLM-ova [64], [66]–[68]. Nastavnici biologije zatim će procijeniti koliko je agent vjerodostojan kao učenik. Na temelju tih provjera i pilota upute agentu dorađivat će se dok se ne ponaša na željeni način. Kako bi istraživanje bilo ponovljivo, navest će se korišteni model i njegova verzija,

postavke i datum, a puni tekst uputa agentu bit će priložen radu. Učenici će agentu pristupati preko sučelja koje postavlja istraživač, bez vlastitih korisničkih računa, u skladu s uvjetima korištenja pružatelja za maloljetne korisnike.

Budući da agent namjerno iznosi pogrešne predodžbe, postoji opasnost da ih učenik prihvati kao točne umjesto da ih ispravi. Zato će svaki razgovor završiti tako da agent, nakon što sažme što je naučio, navede i znanstveno točno objašnjenje. Nastavnik će na kraju intervencije sa svim skupinama proći kroz miskoncepcije koje je agent zastupao.

Tijekom provedbe pratit će se i provodi li se intervencija onako kako je zamišljena, jer se rezultati mogu ispravno protumačiti samo ako se zna kako je intervencija stvarno provedena [97]. Iz zapisa razgovora utvrdit će se koliko je vremena učenik proveo objašnjavajući agentu te je li ga doista poučavao ili je od njega tražio odgovore. U skupini vršnjaka učenici izmjenjuju uloge, pa svaki od njih poučava otprilike polovicu vremena. Zato će se iz snimaka utvrditi i koliko je vremena svaki učenik proveo u ulozi tutora, kako bi se razlika u vremenu poučavanja između skupina mogla uzeti u obzir pri tumačenju rezultata.

D. Instrumenti i analiza podataka

Konceptualno razumijevanje mjerit će se dvorazinskim dijagnostičkim testom, u kojem učenik u prvoj razini bira odgovor, a u drugoj obrazloženje odgovora [98]. Takav test omogućuje razlikovanje razumijevanja, pogađanja i miskoncepcija, a već je primijenjen za fotosintezu i disanje biljaka [88]. Treagust [98] opisuje postupak izrade takvog testa u deset koraka, a test u ovom istraživanju izradit će se prema tom postupku. Najprije će se sadržaj odrediti nizom tvrdnji koje opisuju znanstveno prihvaćeno razumijevanje staničnog disanja, a temelje se na ishodima iz potpoglavlja IV.B. Nastavnici biologije procijenit će jesu li te tvrdnje sadržajno točne i potpune. Zatim će se prikupiti podaci o miskoncepcijama, iz literature opisane u potpoglavlju IV.C i iz razgovora s manjim brojem učenika. Na temelju toga izradit će se zadaci, a ponuđena obrazloženja u drugoj razini uključivat će znanstveno točan odgovor i najčešće miskoncepcije. Zadaci će se provjeriti u pilot-istraživanju analizom težine i diskriminativnosti svakog zadatka, a pouzdanost testa procijenit će se Cronbachovim koeficijentom alfa [99]. Isti test, u usporedivim inačicama, primijenit će se kao pretest, posttest i odgođeni test.

Zapisi razgovora s agentom i snimke poučavanja vršnjaka analizirat će se prema kategorijama izgradnje i prenošenja znanja [21]. Kodiranje će provesti dva neovisna procjenjivača, a njihovo slaganje izrazit će se Cohenovim koeficijentom kappa, koji uzima u obzir i slaganje koje bi nastalo slučajno [100]. Neslaganja će procjenjivači riješiti zajedničkom raspravom. Učenici će na kraju ispuniti i kratki upitnik o iskustvu rada s agentom.

Rezultati testova usporedit će se analizom kovarijance, s rezultatom na pretestu kao kovarijatom. Ako broj razreda bude dovoljan, koristit će se višerazinski model kojim se uzima u obzir grupiranost učenika u razrede [95]. Odgovori iz upitnika i zapisi razgovora analizirat će se i kvalitativno, kako bi se odgovorilo na treće istraživačko pitanje.

E. Etička pitanja, ograničenja i trenutna faza istraživanja

Istraživanje će se provesti u skladu s Etičkim kodeksom istraživanja s djecom [101]. Prije početka bit će zatraženo odobrenje nadležnog etičkog povjerenstva i ravnatelja škola. Učenici stariji od 14 godina sami daju informirani pristanak, ali budući da će se spremati zapisi razgovora, bit će zatražena i suglasnost roditelja za obradu osobnih podataka [101], [102]. Učenici će biti obaviješteni da u razgovor s agentom ne unose osobne podatke, zapisi će se pseudonimizirati, a sudjelovanje je dobrovoljno i učenici mogu odustati u bilo kojem trenutku. Nakon završetka istraživanja učenici iz kontrolne skupine i skupine vršnjaka moći će raditi s agentom, kako nijedna skupina ne bi bila zakinuta.

Glavna ograničenja proizlaze iz provedbe u školskim uvjetima. Razredi i nastavnici razlikuju se, pa nasumični raspored pojedinih učenika nije moguć. Osim toga, razgovor s agentom ne može u potpunosti zamijeniti komunikaciju sa stvarnim učenikom.

Istraživanje je trenutno u fazi pripreme. Pregledana je relevantna literatura, a u tijeku su razvoj agenta i izrada mjernih instrumenata. Sljedeći korak je pilot-istraživanje, kojim će se provjeriti provedivost plana i dobiti povratne informacije za doradu agenta i instrumenata prije glavnog istraživanja. Plan istraživanja još je u razradi, pa će se pojedini elementi, poput veličine uzorka, trajanja intervencije i načina analize podataka, konačno odrediti nakon pilot-istraživanja.

VI. ZAKLJUČAK

Provedbom ovog istraživanja želi se steći dublji uvid u to kako poučavanje LLM-a u ulozi učenika može utjecati na razumijevanje složenih bioloških koncepata poput staničnog disanja. Iako razgovor s modelom ne može u potpunosti zamijeniti stvarnu interakciju među učenicima, pedagoški oblikovan agent mogao bi učenicima pružiti priliku da objašnjavaju, ispravljaju pogreške i grade vlastito razumijevanje, umjesto da od UI-ja samo preuzimaju gotove odgovore. Očekuje se da će rezultati doprinijeti boljem razumijevanju načina na koje UI može podržati generativne procese učenja, a razvijeni agent i iskustva iz njegove primjene mogli bi poslužiti kao osnova za daljnja istraživanja i za nastavnu praksu u prirodoslovnom obrazovanju.

Doprinos istraživanja može se promatrati na tri razine. Na teorijskoj razini rad povezuje učenje poučavanjem i konceptualnu promjenu u situaciji u kojoj je štićenik LLM. Učenik koji agenta treba uvjeriti da napusti pogrešnu predodžbu mora i sam razumjeti zašto je ona pogrešna, pa se može očekivati da poučavanje agenta potiče konceptualnu promjenu i kod samog tutora. Na metodološkoj razini rad nudi postupak oblikovanja i provjere LLM-a u ulozi učenika sa zadanim miskoncepcijama, koji se uz manje prilagodbe može primijeniti i na druge prirodoslovne teme. Na praktičnoj razini rezultati bi nastavnicima mogli pokazati kako LLM uključiti u nastavu tako da učenik objašnjava i argumentira, a ne samo prima gotove odgovore.

Neka pitanja ostat će otvorena i nakon ovog istraživanja. Usporedba poučavanja agenta i poučavanja vršnjaka razmatra se istraživački, bez unaprijed postavljene hipoteze, a odgođeni test pokazat će samo zadržavaju li se učinci nekoliko tjedana nakon intervencije. Jesu li te promjene trajne, moći će pokazati tek dugotrajnija istraživanja.

LITERATURA

[1] M. Montenegro-Rueda et al., “Impact of the implementation of ChatGPT in education: A systematic review,” Computers, vol. 12, no. 8, Art. no. 153, 2023, doi: 10.3390/computers12080153.

[2] H. Crompton and D. Burke, “The educational affordances and challenges of ChatGPT: State of the field,” TechTrends, vol. 68, no. 2, pp. 380–392, 2024, doi: 10.1007/s11528-024-00939-0.

[3] F. Farhi, R. Jeljeli, I. Aburezeq, F. F. Dweikat, S. A. Al-shami, and R. Slamene, “Analyzing the students’ views, concerns, and perceived ethics about chat GPT usage,” Comput. Educ.: Artif. Intell., vol. 5, Art. no. 100180, 2023, doi: 10.1016/j.caeai.2023.100180.

[4] D. Baidoo-Anu and L. Owusu Ansah, “Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning,” J. AI, vol. 7, no. 1, pp. 52–62, 2023, doi: 10.61969/jai.1337500.

[5] E. Kasneci et al., “ChatGPT for good? On opportunities and challenges of large language models for education,” Learn. Individ. Differ., vol. 103, Art. no. 102274, 2023.

[6] D. R. E. Cotton, P. A. Cotton, and J. R. Shipway, “Chatting and cheating: Ensuring academic integrity in the era of ChatGPT,” Innov. Educ. Teach. Int., vol. 61, no. 2, pp. 228–239, 2024, doi: 10.1080/14703297.2023.2190148.

[7] M. C. Wittrock, “Generative processes of comprehension,” Educ. Psychol., vol. 25, no. 5, pp. 531–541, 1990, doi: 10.1207/s15326985ep2505_5.

[8] R. Osborne and M. C. Wittrock, “The generative learning model and its implications for science education,” Stud. Sci. Educ., vol. 12, no. 1, pp. 59–87, 1985.

[9] L. Fiorella and R. E. Mayer, “Eight ways to promote generative learning,” Educ. Psychol. Rev., vol. 28, no. 4, pp. 717–741, 2016.

[10] G. Brod, “Generative learning: Which strategies for what age?,” Educ. Psychol. Rev., vol. 33, no. 4, pp. 1295–1318, 2021, doi: 10.1007/s10648-020-09574-5.

[11] M. T. H. Chi and R. Wylie, “The ICAP framework: Linking cognitive engagement to active learning outcomes,” Educ. Psychol., vol. 49, no. 4, pp. 219–243, 2014, doi: 10.1080/00461520.2014.965823.

[12] L. Fiorella, “Making sense of generative learning,” Educ. Psychol. Rev., vol. 35, no. 2, Art. no. 50, 2023, doi: 10.1007/s10648-023-09769-7.

[13] L. Fiorella and R. E. Mayer, Learning as a Generative Activity: Eight Learning Strategies that Promote Understanding. New York, NY, USA: Cambridge Univ. Press, 2015.

[14] M. C. Wittrock, “Learning as a generative process,” Educ. Psychol., vol. 11, no. 2, pp. 87–95, 1974, doi: 10.1080/00461527409529129.

[15] J. A. Bargh and Y. Schul, “On the cognitive benefits of teaching,” J. Educ. Psychol., vol. 72, no. 5, pp. 593–604, 1980, doi: 10.1037/0022-0663.72.5.593.

[16] A. Renkl, “Learning for later teaching: An exploration of mediational links between teaching expectancy and learning results,” Learn. Instr., vol. 5, no. 1, pp. 21–36, 1995.

[17] L. Fiorella and R. E. Mayer, “The relative benefits of learning by teaching and teaching expectancy,” Contemp. Educ. Psychol., vol. 38, no. 4, pp. 281–288, 2013.

[18] L. Fiorella and R. E. Mayer, “Role of expectations and explanations in learning by teaching,” Contemp. Educ. Psychol., vol. 39, no. 2, pp. 75–85, 2014.

[19] K. Kobayashi, “Learning by preparing-to-teach and teaching: A meta-analysis,” Jpn. Psychol. Res., vol. 61, no. 3, pp. 192–204, 2019.

[20] V. Hoogerheide, S. M. M. Loyens, and T. van Gog, “Effects of creating video-based modeling examples on learning and transfer,” Learn. Instr., vol. 33, pp. 108–119, 2014.

[21] R. D. Roscoe and M. T. H. Chi, “Understanding tutor learning: Knowledge-building and knowledge-telling in peer tutors’ explanations,” Rev. Educ. Res., vol. 77, no. 4, pp. 534–574, 2007.

[22] N. Matsuda, E. Yarzebinski, V. Keiser, R. Raizada, W. W. Cohen, and K. R. Koedinger, “Studying the effect of a competitive game show in a learning by teaching environment,” Int. J. Artif. Intell. Educ., vol. 23, no. 1–4, pp. 1–21, 2013.

[23] D. B. Chin, I. M. Dohmen, B. H. Cheng, M. A. Oppezzo, C. C. Chase, and D. L. Schwartz, “Preparing students for future learning with teachable agents,” Educ. Technol. Res. Dev., vol. 58, no. 6, pp. 649–669, 2010, doi: 10.1007/s11423-010-9154-5.

[24] R. D. Roscoe, J. R. Segedy, B. Sulcer, H. Jeong, and G. Biswas, “Shallow strategy development in a teachable agent environment designed to support self-regulated learning,” Comput. Educ., vol. 62, pp. 286–297, 2013, doi: 10.1016/j.compedu.2012.11.018.

[25] R. D. Roscoe, “Self-monitoring and knowledge-building in learning by teaching,” Instr. Sci., vol. 42, no. 3, pp. 327–351, 2014.

[26] R. D. Roscoe and M. T. H. Chi, “Tutor learning: The role of explaining and responding to questions,” Instr. Sci., vol. 36, no. 4, pp. 321–350, 2008, doi: 10.1007/s11251-007-9034-5.

[27] M. T. H. Chi, N. de Leeuw, M.-H. Chiu, and C. LaVancher, “Eliciting self-explanations improves understanding,” Cogn. Sci., vol. 18, no. 3, pp. 439–477, 1994.

[28] E. B. Coleman, A. L. Brown, and I. D. Rivkin, “The effect of instructional explanations on learning from scientific texts,” J. Learn. Sci., vol. 6, no. 4, pp. 347–365, 1997.

[29] C. C. Chase, D. B. Chin, M. A. Oppezzo, and D. L. Schwartz, “Teachable agents and the protégé effect: Increasing the effort towards learning,” J. Sci. Educ. Technol., vol. 18, no. 4, pp. 334–352, 2009.

[30] D. Duran, “Learning-by-teaching: Evidence and implications as a pedagogical mechanism,” Innov. Educ. Teach. Int., vol. 54, no. 5, pp. 476–484, 2017, doi: 10.1080/14703297.2016.1156011.

[31] L. F. Annis, “The processes and effects of peer tutoring,” Human Learning, vol. 2, no. 1, pp. 39–47, 1983.

[32] C. A. Benware and E. L. Deci, “Quality of learning with an active versus passive motivational set,” Am. Educ. Res. J., vol. 21, no. 4, pp. 755–765, 1984.

[33] L. Fiorella and S. Kuhlmann, “Creating drawings enhances learning by teaching,” Appl. Cogn. Psychol., vol. 34, no. 3, pp. 629–639, 2020.

[34] N. M. Webb, “Peer interaction and learning in small groups,” Int. J. Educ. Res., vol. 13, no. 1, pp. 21–39, 1989.

[35] B. Malik Pelumi, K. Adeyinka Oluwaseun, and B. Folorunsho Emmanuel, “Interactivity as a retention factor in learning biology through the protégé effect,” J. Teach. Learn., vol. 19, no. 1, pp. 107–130, 2025, doi: 10.22329/jtl.v19i1.8731.

[36] N. Sabnis and T. Nagashima, “Empowering learners: Chatbot-mediated ‘learning-by-teaching’,” in Ext. Abstr. CHI Conf. Hum. Factors Comput. Syst. (CHI EA ’24), Honolulu, HI, USA, 2024, pp. 1–9, doi: 10.1145/3613905.3650754.

[37] A. Chen, Y. Wei, H. Le, and Y. Zhang, “Learning by teaching with ChatGPT: The effect of teachable ChatGPT agent on programming education,” Br. J. Educ. Technol., vol. 57, no. 1, pp. 163–184, 2026, doi: 10.1111/bjet.70001.

[38] H. Jin, S. Lee, H. Shin, and J. Kim, “‘Teach AI how to code’: Using large language models as teachable agents for programming education,” arXiv:2309.14534, 2023.

[39] J. Meyer, T. Jansen, R. Schiller, L. W. Liebenow, M. H. Steinbach, A. Horbach, and J. Fleckenstein, “Using LLMs to bring evidence-based feedback into the classroom: AI-generated feedback increases secondary students’ text revision, motivation, and positive emotions,” Comput. Educ.: Artif. Intell., vol. 6, Art. no. 100199, 2024, doi: 10.1016/j.caeai.2023.100199.

[40] H. Bastani, O. Bastani, A. Sungu, H. Ge, Ö. Kabakcı, and R. Mariman, “Generative AI without guardrails can harm learning: Evidence from high school mathematics,” Proc. Natl. Acad. Sci. U.S.A., vol. 122, no. 26, Art. no. e2422633122, 2025, doi: 10.1073/pnas.2422633122.

[41] O. Zawacki-Richter, V. I. Marín, M. Bond, and F. Gouverneur, “Systematic review of research on artificial intelligence applications in higher education – where are the educators?,” Int. J. Educ. Technol. High. Educ., vol. 16, no. 1, Art. no. 39, 2019.

[42] T. Susnjak, “ChatGPT: The end of online exam integrity?,” arXiv:2212.09292, 2022.

[43] J. Freeman, “Student generative AI survey 2025,” Higher Education Policy Institute, HEPI Policy Note 61, Feb. 2025. [Online]. Available: https://www.hepi.ac.uk/reports/student-generative-ai-survey-2025/

[44] Pew Research Center, “About a quarter of U.S. teens have used ChatGPT for schoolwork – double the share in 2023,” Jan. 2025. [Online]. Available: https://www.pewresearch.org/short-reads/2025/01/15/about-a-quarter-of-us-teens-have-used-chatgpt-for-schoolwork-double-the-share-in-2023/

[45] CARNET, „Sažetak glavnih nalaza istraživanja: Rezultati istraživanja o korištenju digitalne tehnologije i umjetne inteligencije te dobrobiti djece i mladih,” projekt BrAIn, ožujak 2026. [Online]. Available: https://brain.hr/wp-content/uploads/2026/03/Brain_istrazivanje_nalazi.pdf

[46] N. Črček and J. Patekar, “Writing with AI: University students’ use of ChatGPT,” J. Lang. Educ., vol. 9, no. 4, pp. 128–138, 2023, doi: 10.17323/jle.2023.17379.

[47] G. Pitts, V. Marcus, and S. Motamedi, “Student perspectives on the benefits and risks of AI in education,” in Proc. 2025 ASEE Annu. Conf. Expo., 2025, arXiv:2505.02198.

[48] O. M. Schei, A. Møgelvang, and K. Ludvigsen, “Perceptions and use of AI chatbots among students in higher education: A scoping review of empirical studies,” Educ. Sci., vol. 14, no. 8, Art. no. 922, 2024, doi: 10.3390/educsci14080922.

[49] V. R. Lee, D. Pope, S. Miles, and R. C. Zárate, “Cheating in the age of generative AI: A high school survey study of cheating behaviors

before and after the release of ChatGPT," Comput. Educ.: Artif. Intell., vol. 7, Art. no. 100253, 2024, doi: 10.1016/j.caeai.2024.100253.

[50] L. Chen, P. Chen, and Z. Lin, "Artificial intelligence in education: A review," IEEE Access, vol. 8, pp. 75264–75278, 2020, doi: 10.1109/ACCESS.2020.2988510.

[51] F. Miao and W. Holmes, Guidance for Generative AI in Education and Research. Paris, France: UNESCO, 2023.

[52] L. Campo, N. Delgado, J. M. Etxabe-Urbieta, H. Kanso, and M. L. Gueye, "Relationship between the use of ChatGPT and plagiarism in higher education: The influence of gender, age and previous academic results," Innov. High. Educ., vol. 51, no. 2, pp. 513–532, 2026, doi: 10.1007/s10755-025-09830-z.

[53] W. Holmes et al., "Ethics of AI in education: Towards a community-wide framework," Int. J. Artif. Intell. Educ., vol. 32, no. 3, pp. 504–526, 2022, doi: 10.1007/s40593-021-00239-1.

[54] M. Sallam, "ChatGPT utility in healthcare education, research, and practice: Systematic review on the promising perspectives and valid concerns," Healthcare, vol. 11, no. 6, Art. no. 887, 2023, doi: 10.3390/healthcare11060887.

[55] G. Biswas, D. L. Schwartz, K. Leelawong, and N. J. Vye, "Learning by teaching: A new agent paradigm for educational software," Appl. Artif. Intell., vol. 19, no. 3–4, pp. 363–392, 2005.

[56] A. Silvervarg, R. Wolf, K. P. Blair, M. Haake, and A. Gulz, "How teachable agents influence students' responses to critical constructive feedback," J. Res. Technol. Educ., vol. 53, no. 1, pp. 67–88, 2021, doi: 10.1080/15391523.2020.1784812.

[57] J. Tan and G. Biswas, "The role of feedback in preparation for future learning: A case study in learning by teaching environments," in Intelligent Tutoring Systems (LNCS, vol. 4053). Berlin, Germany: Springer, 2006, pp. 370–381, doi: 10.1007/11774303_37.

[58] N. Matsuda, W. Weng, and N. Wall, "The effect of metacognitive scaffolding for learning by teaching a teachable agent," Int. J. Artif. Intell. Educ., vol. 30, no. 1, pp. 1–37, 2020, doi: 10.1007/s40593-019-00190-2.

[59] E. Mollick and L. Mollick, "Assigning AI: Seven approaches for students, with prompts," SSRN Working Paper, 2023.

[60] L. Jin, B. Lin, M. Hong, K. Zhang, and H.-J. So, "Exploring the impact of an LLM-powered teachable agent on learning gains and cognitive load in music education," arXiv:2504.00636, 2025.

[61] V. Dentella, F. Günther, E. Murphy, G. Marcus, and E. Leivada, "Testing AI on language comprehension tasks reveals insensitivity to underlying meaning," Sci. Rep., vol. 14, Art. no. 28083, 2024, doi: 10.1038/s41598-024-79531-8.

[62] N. Asher, S. Bhar, A. Chaturvedi, J. Hunter, and S. Paul, "Limits for learning with language models," arXiv, 2023, doi: 10.48550/arXiv.2306.12213.

[63] W. Holmes, M. Bialik, and C. Fadel, Artificial Intelligence in Education: Promises and Implications for Teaching and Learning. Boston, MA, USA: Center for Curriculum Redesign, 2019.

[64] S. Miller and N. Bosch, "Prompting for teachability: Designing novice personas in LLMs for learning by teaching contexts," in Proc. 16th Int. Learn. Anal. Knowl. Conf. (LAK '26), Bergen, Norway, 2026, pp. 822–828, doi: 10.1145/3785022.3785067.

[65] L. Jin and H.-J. So, "Pedagogically steered LLM-based teachable agents for scaffolding tutor learning in learning-by-teaching," in Artificial Intelligence in Education, AIED 2026, Commun. Comput. Inf. Sci., vol. 3033, E. G. Blanchard, G. Chen, M. Chi, and S. Isotani, Eds. Cham, Switzerland: Springer, 2026, doi: 10.1007/978-3-032-29794-5_48.

[66] M. Sharma et al., "Towards understanding sycophancy in language models," in Proc. Int. Conf. Learn. Represent. (ICLR), 2024, arXiv:2310.13548.

[67] C. Arvin, "'Check my work?': Measuring sycophancy in a simulated educational context," presented at the KDD Workshop on Ethical Artificial Intelligence (EAI), Toronto, Canada, 2025, arXiv:2506.10297.

[68] K. Li, T. Liu, N. Bashkansky, D. Bau, F. Viégas, H. Pfister, and M. Wattenberg, "Measuring and controlling instruction (in)stability in language model dialogs," arXiv:2402.10962, 2024.

[69] L. Huang, W. Yu, W. Ma, W. Zhong, Z. Feng, H. Wang, Q. Chen, W. Peng, X. Feng, B. Qin, and T. Liu, "A survey on hallucination in large language models: Principles, taxonomy, challenges, and open questions," ACM Trans. Inf. Syst., vol. 43, no. 2, Art. no. 42, pp. 1–55, 2025, doi: 10.1145/3703155.

[70] A. T. Kalai, O. Nachum, S. S. Vempala, and E. Zhang, "Why language models hallucinate," arXiv:2509.04664, 2025.

[71] N. Kandpal, H. Deng, A. Roberts, E. Wallace, and C. Raffel, "Large language models struggle to learn long-tail knowledge," in Proc. 40th Int. Conf. Mach. Learn. (ICML), PMLR, vol. 202, 2023, pp. 15696–15707.

[72] D. R. Krathwohl, "A revision of Bloom's taxonomy: An overview," Theory Into Pract., vol. 41, no. 4, pp. 212–218, 2002.

[73] J. D. Novak, "Meaningful learning: The essential factor for conceptual change," Sci. Educ., vol. 86, no. 4, pp. 548–571, 2002.

[74] M. T. H. Chi, "Commonsense conceptions of emergent processes: Why some misconceptions are robust," J. Learn. Sci., vol. 14, no. 2, pp. 161–199, 2005.

[75] J. J. Mintzes, J. H. Wandersee, and J. D. Novak, Teaching Science for Understanding: A Human Constructivist View. San Diego, CA, USA: Academic Press, 1998.

[76] R. Duit and D. F. Treagust, "Conceptual change: A powerful framework for improving science teaching and learning," Int. J. Sci. Educ., vol. 25, no. 6, pp. 671–688, 2003.

[77] G. J. Posner, K. A. Strike, P. W. Hewson, and W. A. Gertzog, "Accommodation of a scientific conception: Toward a theory of conceptual change," Sci. Educ., vol. 66, no. 2, pp. 211–227, 1982, doi: 10.1002/sce.3730660207.

[78] S. Vosniadou, "Capturing and modeling the process of conceptual change," Learn. Instr., vol. 4, no. 1, pp. 45–69, 1994, doi: 10.1016/0959-4752(94)90018-3.

[79] C. A. Chinn and W. F. Brewer, "The role of anomalous data in knowledge acquisition: A theoretical framework and implications for science instruction," Rev. Educ. Res., vol. 63, no. 1, pp. 1–49, 1993.

[80] Ministarstvo znanosti i obrazovanja, „Odluka o donošenju kurikuluma za nastavni predmet Biologije za osnovne škole i gimnazije u Republici Hrvatskoj," Narodne novine, br. 7/2019, 2019.

[81] Ministarstvo znanosti i obrazovanja, „Prijedlog godišnjeg izvedbenog kurikuluma za Biologiju u 3. razredu srednje škole za školsku godinu 2021./2022.," 2021. [Online]. Available: https://i-nastava.gov.hr/UserDocsImages//dokumenti/2021-2022/GIK-Biologija//BIO_3%20razred%20SS_2021-2022.pdf

[82] I. Sorić, S. Šimić Šašić, J. Filipi, I. Lončar, D. Luketić, and M. Zulić, Eds., Priručnik za izradu ishoda učenja Sveučilišta u Zadru. Zadar, Hrvatska: Sveučilište u Zadru, 2018. [Online]. Available: https://www.unizd.hr/Portals/0/kvaliteta/Prirucnik_za_izradu_ishoda_ucenja.pdf

[83] R. Schwartz and M. H. Brown, "Understanding photosynthesis and cellular respiration: Encouraging a view of biological nested systems," in Multiple Representations in Biological Education, D. F. Treagust and C.-Y. Tsui, Eds. Dordrecht, Netherlands: Springer, 2013, pp. 203–223, doi: 10.1007/978-94-007-4192-8_12.

[84] C.-Y. Lin and R. Hu, "Students' understanding of energy flow and matter cycling in the context of the food chain, photosynthesis, and respiration," Int. J. Sci. Educ., vol. 25, no. 12, pp. 1529–1544, 2003, doi: 10.1080/0950069032000052045.

[85] Z. Aşçı, Ş. Özkan, and C. Tekkaya, "Students' misconceptions about respiration: A cross-age study," Eğitim ve Bilim, vol. 26, no. 120, pp. 29–36, 2001.

[86] J. Seymour and B. Longden, "Respiration—that's breathing isn't it?," J. Biol. Educ., vol. 25, no. 3, pp. 177–183, 1991.

[87] C. D. Wilson, C. W. Anderson, M. Heidemann, J. E. Merrill, B. W. Merritt, G. Richmond, D. F. Sibley, and J. M. Parker, "Assessing students' ability to trace matter in dynamic systems in cell biology," CBE—Life Sci. Educ., vol. 5, no. 4, pp. 323–331, 2006, doi: 10.1187/cbe.06-02-0142.

[88] F. Haslam and D. F. Treagust, "Diagnosing secondary students' misconceptions of photosynthesis and respiration in plants using a two-tier multiple choice instrument," J. Biol. Educ., vol. 21, no. 3, pp. 203–211, 1987.

[89] V. Vančugovienė, I. Södervik, E. Lehtinen, and J. McMullen, "Individual differences in secondary school students' conceptual knowledge: Latent profile analysis of biology concepts," Learn. Individ. Differ., vol. 111, Art. no. 102436, 2024, doi: 10.1016/j.lindif.2024.102436.

[90] N. Mahror and S. N. D. Mahmud, "Secondary school students' cognitive structures and misconceptions in respiration topic," Humanit. Soc. Sci. Rev., vol. 8, no. 3, pp. 1272–1284, 2020, doi: 10.18510/hssr.2020.8313.

[91] C. J. Songer and J. J. Mintzes, “Understanding cellular respiration: An analysis of conceptual change in college biology,” J. Res. Sci. Teach., vol. 31, no. 6, pp. 621–637, 1994.

[92] E. Özay and H. Öztas, “Secondary students’ interpretations of photosynthesis and plant nutrition,” J. Biol. Educ., vol. 37, no. 2, pp. 68–70, 2003, doi: 10.1080/00219266.2003.9655853.

[93] W. R. Shadish, T. D. Cook, and D. T. Campbell, Experimental and Quasi-Experimental Designs for Generalized Causal Inference. Boston, MA, USA: Houghton Mifflin, 2002.

[94] F. Faul, E. Erdfelder, A.-G. Lang, and A. Buchner, “G*Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences,” Behav. Res. Methods, vol. 39, no. 2, pp. 175–191, 2007.

[95] L. V. Hedges and E. C. Hedberg, “Intraclass correlation values for planning group-randomized trials in education,” Educ. Eval. Policy Anal., vol. 29, no. 1, pp. 60–87, 2007.

[96] The Design-Based Research Collective, “Design-based research: An emerging paradigm for educational inquiry,” Educ. Res., vol. 32, no. 1, pp. 5–8, 2003.

[97] C. L. O’Donnell, “Defining, conceptualizing, and measuring fidelity of implementation and its relationship to outcomes in K–12 curriculum intervention research,” Rev. Educ. Res., vol. 78, no. 1, pp. 33–84, 2008. https://doi.org/10.3102/0034654307313793

[98] D. F. Treagust, “Development and use of diagnostic tests to evaluate students’ misconceptions in science,” Int. J. Sci. Educ., vol. 10, no. 2, pp. 159–169, 1988, doi: 10.1080/0950069880100204.

[99] L. J. Cronbach, “Coefficient alpha and the internal structure of tests,” Psychometrika, vol. 16, no. 3, pp. 297–334, 1951, doi: 10.1007/BF02310555.

[100] J. Cohen, “A coefficient of agreement for nominal scales,” Educ. Psychol. Meas., vol. 20, no. 1, pp. 37–46, 1960, doi: 10.1177/001316446002000104.

[101] M. Ajduković and G. Keresteš, Eds., Etički kodeks istraživanja s djecom, 2. rev. izd. Zagreb, Hrvatska: Vijeće za djecu Vlade Republike Hrvatske, 2020.

[102] Zakon o provedbi Opće uredbe o zaštiti podataka, Narodne novine, br. 42/2018.