Povezanost motivacijskih uvjerenja sa strategijama učenja i uključenosti učenika u učenje i nastavu biologije

Kotarski, Maja

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Department of Croatian Studies / Sveučilište u Zagrebu, Hrvatski studiji**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:111:007174

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI
UNIVERSITY OF ZAGREB
CENTER FOR CROATIAN STUDIES

Repository / Repozitorij:

Repository of University of Zagreb, Centre for Croatian Studies

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI

Maja Kotarski

POVEZANOST MOTIVACIJSKIH UVJERENJA SA STRATEGIJAMA UČENJA I UKLJUČENOSTI UČENIKA U UČENJE I NASTAVU BIOLOGIJE

DIPLOMSKI RAD

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI
ODSJEK ZA PSIHOLOGIJU

MAJA KOTARSKI

POVEZANOST MOTIVACIJSKIH UVJERENJA SA STRATEGIJAMA UČENJA I UKLJUČENOSTI UČENIKA U UČENJE I NASTAVU BIOLOGIJE

DIPLOMSKI RAD

Mentor: prof. dr. sc. Andreja Brajša-Žganec

Zagreb, 2019.

Povezanost motivacijskih uvjerenja sa strategijama učenja i uključenosti učenika u učenje i nastavu biologije

Sažetak

Cilj ovog istraživanja bio je ispitati odnos motivacijskih uvjerenja (samoefikasnost i subjektivna vrijednost) sa strategijama učenja i uključenošću učenika u učenje i nastavu biologije. U istraživanju je sudjelovalo 199 učenika drugih i trećih razreda triju općih gimnazija s područja Krapinsko-zagorske županije. Podaci su prikupljani odlaskom u svaku gimnaziju gdje su učenici ispunjavali upitnik koji je sadržavao četiri mjerna instrumenta: Skalu samoefikasnosti, Skalu subjektivnih vrijednosti, Skalu uključenosti u nastavu biologije i Skalu strategija učenja te su prikupljeni i neki sociodemografski podaci. Korišteni skup prediktorskih varijabli (spol, dob, prosjek ocjena na kraju prošle školske godine, samoefikasnost i subjektivna vrijednost) objasnio je tek dio varijance kriterijskih varijabli, a prema rezultatima hijerarhijske regresijske analize to je 23.7% varijance bihevioralne i 40.9% kognitivne uključenosti, 26% varijance strategija (meta)kognitivne kontrole tijeka, 22.4% varijance dubokog kognitivnog procesiranja i 25.9% varijance površinskog kognitivnog procesiranja. Rezultati pokazuju kako je subjektivna vrijednost najznačajniji samostalni prediktor bihevioralne i kognitivne uključenosti te strategija dubokog kognitivnog procesiranja. Za strategije ciklusa (meta)kognitivne kontrole učenja kao najznačajniji samostalni prediktor pokazao se spol, a za strategije površinskog kognitivnog procesiranja prosjek ocjena na kraju prošle školske godine. Iako je prema prethodnim istraživanjima očekivano da će samoefikasnost biti značajan prediktor za sve kriterijske varijable, prema rezultatima je pokazano da je važan prediktor samo strategija površinskog kognitivnog procesiranja.

Ključne riječi: motivacijska uvjerenja, uključenost u nastavu, strategije učenja, biologija

The relationship between motivational beliefs, learning strategies and student engagement in biology

Abstract

The aim of this study was to examine relations of motivation beliefs (self-efficacy and subjective value), learning strategies and student engagement in biology. The participants were 199 second and third grade students from three high school in Krapina-zagorje county. In each school the students filled out the quesstionare which contained four measuring instruments: Self-efficacy scale, Subjective task values scale, Student engagement in biology scale, Learning Strategies Scale and some general information. The set of predictor variables used (gender, age, grade point average, self-efficacy, subjective value) explained only the part of variance of criterian variables and according to results of the hierarchical regression analysis that was 23.7% variance of bihevioral and 40.9% variance of cognitive engagement, 26% variance of strategies of cycles of metacognitive control, 22.4% variance of strategies of deep cognitive processing and 25.9% variance of strategies of surface cognitive processing. The results have shown that the subjective value explained the largest part of variance of bihevioral and cognitive engagement and strategies of deep cognitive processing. For strategies of cycles of metacognitive control, gender explained the largest part of variance and for strategies of surface cognitive processing that was the grade point average at the end of last school year. Although the previously studies indicated that the self-efficacy is significantly predictor for all of criteria variables, the results od this study showed that it is important for only strategies of surface cognitive processing.

Key words: motivational beliefs, student engagement, learning strategies, biology

Sadržaj

Uvod 2

Teorija očekivanja i vrijednosti 3

Samoefikasnost 5

Strategije učenja 7

Uključenost 10

Ciljevi i problemi istraživanja 13

Metoda 13

Sudionici 13

Postupak 13

Mjerni instrumenti 14

Rezultati 16

Rasprava 23

Doprinosi istraživanja 28

Ograničenja istraživanja i prijedlozi za buduća istraživanja 30

Zaključak 32

Literatura 34

Uvod

U današnjem modernom društvu, uz napredak znanosti i tehnologije, nezaobilazan je i napredak takozvanog STEM područja (eng. *science, technology, engineering, mathematics)* koji je privukao interes na mnogim radnim mjestima, u politici i obrazovanju (Gonzalez i Kuenzi, 2012). Mnoge države ulažu u inovacije kako bi što više poticale gospodarski rast i razvoj, a samim time smanjile i nezaposlenost te se okreću inovacijama koje su usmjerene na napredak znanosti, tehnologije, inženjerstva i matematike (STEM područja) budući da sve veći broj radnih mjesta zahtjeva STEM znanje (Corlu, Capraro i Capraro, 2014). Kako bi radna snaga stekla znanja i vještine koje su potrebne za rad, u području školstva se sve više uvode STEM programi koji uključuju obrazovne aktivnosti na svim razinama školstva, od predškole do postdoktorata i to kroz formalne i neformalne edukacije (Gonzalez i Kuenzi, 2012). Samim time želi se povećati i broj kvalitetnih nastavnika koji će što bolje prenijeti znanje, a usmjeravaju se i na povećanje općenitog interesa i motivacije za STEM područje (Corlu i sur., 2014).

Motivacija je jedna od najvažnijih komponenti koja djeluje na akademske ishode jer ne samo da potiče na učenje već i utječe na to kako, što i koliko će učenici nešto učiti (Vizek Vidović, Rijavec, Vlahović-Štetić i Miljković, 2014). Budući da je STEM područje od primarnog interesa, to znači da se proučava specifična motivacija za učenjem koja se odnosi na usvajanje sadržaja u određenom školskom predmetu ili području. Predmeti STEM područja, a posebice prirodne znanosti su često učenicima teški za učiti jer su mnogi pojmovi na apstraktnoj razini te se potiče učenje otkrivanjem, grupni radovi i eksperimenti pomoću kojih učenici mogu usvajati nove činjenice i znanstveno razmišljanje (Vizek Vidović i sur., 2014). Primijećeno je da se obrazovanje usmjerilo više na fizikalne znanosti, kemiju i fiziku koje imaju izravniju vezu s matematikom i inženjerstvom nego biologija koju se manje ističe i istražuje od ostalih predmeta STEM područja (Riechert i Post, 2010). Jedan od načina da se biologija integrira zajedno s ostalim predmetima jest multidisciplinarni projekt *Biologija u kutiji* (*Biology in a Box)* koji uključuje matematičke i fizičke elemente u vježbe biologije gdje god je to moguće (Riechert i Post, 2010). Osim na taj način, interes za biologiju i pozitivan stav prema njoj može se potaknuti i različitim metodama poučavanja koji je ispitivan na uzorku studenata prve godine. Oni su prepoznali vrijednost istraživačke nastave ponajviše u biologiji, primjerice *mikroskopiranje stanice vlastitog jezika* (Matijević, 2017), što je potaknulo njihov interes za biologijom i njezinim učenjem i smanjilo stav učenika da je biologija teška i nezanimljiva. Slično istraživanje provedeno je na srednjoškolcima u kojem su ispitivani stavovi prema

botanici i pokazano je da postoji pozitivna povezanost prosječne ocjene iz biologije te učinka u testu znanja sa stavom što znači da oni učenici koji imaju pozitivniji stav prema botanici, a ujedno i prema biologiji, postižu i bolji uspjeh (Zugaj, 2014). Prirodoslovni predmeti se u hrvatskom osnovnom obrazovanju nalaze među najmanje omiljenima, gdje je kemija na prvom mjestu, a biologija na posljednjem što znači da im je ona omiljenija od ostalih prirodoslovnih predmeta (Marušić, 2006; prema Domazet, 2009). Razlog tome može biti taj što biologija ima veću primjenjivost sadržaja na vlastiti život učenika, što je dio motivacije koji se treba istražiti. Upravo će motivacijska uvjerenja (samoefikasnost i subjektivna vrijednost) biti od glavnog interesa u ovom istraživanju kako bi se ispitao njihov odnos sa strategijama učenja biologije i uključenošću učenika u nastavu biologije. Budući da je odnos motivacijskih uvjerenja i uključenosti učenika u nastavu istraživan ponajviše u matematici, fizici i kemiji, odabrana je biologija kao specifičan predmet STEM područja. Osim toga, odnos motivacijskih uvjerenja i strategija učenja nije dovoljno istražen pa se želi proučiti kakav je odnos motivacije i odabira načina učenja biologije kod srednjoškolaca.

Teorija očekivanja i vrijednosti

Brojni teorijski okviri nastoje objasniti ulogu motivacije u psihologiji obrazovanja usmjeravajući se na proces učenja, akademske ishode i postignuće te obrazovne odabire, a među njima se kao jedan od najvažnijih suvremenih okvira ističe teorija očekivanja i vrijednosti autora Wigfielda, Ecclesa i njihovih suradnika (Eccles, 2005; Eccles i Wigfield 2002; Wigfield i Eccles, 2000). Važnost se ističe u sveobuhvatnosti teorije koja ne zanemaruje kontekstualni, socijalni i kognitivni utjecaj. Temeljno polazište teorije jest da na akademsko postignuće i obrazovne odabire te izvedbu zadatka najviše utječu očekivanja uspjeha u aktivnosti i subjektivne vrijednosti tih aktivnosti koja oblikuju uvjerenja o vlastitim sposobnostima u određenom području i težina zadatka (Eccles i Wigfield, 2002). Očekivanja i vrijednosti su pod utjecajem specifičnih vjerovanja osobe, percepciji težine zadatka i njezinih ciljeva, a ona su povezana s iskustvima pojedinca, kulturalnim normama, percepcijom stavova te različitim kontekstualnim utjecajima (Wigfield i Eccles, 1992, prema Marušić, 2006).

Očekivanje uspjeha definira se kao uvjerenje osobe o tome koliko će biti uspješna u nekoj aktivnosti u bližoj ili daljnjoj budućnosti (Eccles i Wigfield, 2002). Uvjerenje o sposobnosti ili percepcija vlastitih sposobnosti definira se kao procjena vlastite kompetentnosti u određenom području te se taj konstrukt konceptualno razlikuje od očekivanja uspjeha, no

empirijski su visoko povezani jer se pokazalo da ih učenici ne razlikuju u stvarnim situacijama postignuća (Eccles i Wigfield, 2002; prema Marušić, 2006).

Drugi konstrukt koji je ključan u teoriji očekivanja i vrijednosti jest subjektivna vrijednost zadatka koja se odnosi na uvjerenja osobe o razlozima zbog kojih se uključuju u neku aktivnost i kako ona zadovoljava njegove potrebe, a sastoji se od četiri komponente (Eccles i Wigfield, 2002).

Prva komponenta subjektivne vrijednost jest *važnost ili vrijednost postignuća* koja se odnosi na važnost uspjeha ili sudjelovanja osobe u određenoj aktivnosti. Usko je povezana s identitetom osobe, odnosno njegovom aktualnom ili idealnom slikom o sebi jer će osobi biti važni oni zadaci i aktivnosti u kojima može izraziti važne aspekte svojeg samopoimanja (Rovan, Pavlin-Bernardić i Vlahović Štetić, 2013). Prema Eccles (2005), ovakva se konceptualizacija važnosti uklapa u šire teorije slaganja pojedinca i okoline koje naglašavaju da je za optimalnu motivaciju važno dobro slaganje mogućnosti koje nudi okolina s potrebama pojedinca. Komponenta važnosti ovisi o tome koliko se osobi pruža mogućnost ostvarenja vlastitih potreba, ciljeva i vrijednosti te će se više angažirati u onim zadacima i više cijeniti one koji joj omogućuju ostvarenje istih (Marušić, 2006).

Druga komponenta, *interes ili intrinzična vrijednost*, predstavlja užitak koji osoba doživljava tijekom obavljanja aktivnosti ili pretpostavljeni užitak koji pojedinac očekuje u svojem budućem bavljenju nekom aktivnosti (Eccles, 2005).

Treća komponenta vrijednosti jest *korisnost ili utilitarna vrijednost* i određuje se prema tome koliko se zadatak uklapa u buduće planove osobe. Odnosi se na to koliko je aktivnost korisna da bi se postigao neki osobni važni cilj u bližoj budućnosti kao što je ugađanje želja roditeljima, ili u daljoj budućnosti kao što je upis u željenu srednju školu, fakultet ili pronalazak posla u željenoj profesiji (Jugović, Baranović i Marušić, 2012). Prema tome, ako učenik nakon srednje škole želi upisati medicinski fakultet, ulagat će više truda i napora u učenje biologije koje će mu pomoći pri upisu i prijemnom ispitu.

Posljednja komponenta jest *percipirana cijena* koja se odnosi na uvjerenje o potencijalnim gubicima vremena i energije koje je učenik mogao utrošiti na bavljenje drugim aktivnostima, a ne učenjem, zatim na količinu napora koji treba uložiti u zadatak te na njezinu emocionalnu cijenu (Eccles, 2005). Percipirana cijena je pod utjecajem mnogih faktora kao što su strah od neuspjeha, očekivanje roditelja, ispitna anksioznost te strah od socijalnih posljedica uspjeha (Rovan i sur., 2013). Sveukupno gledajući iz perspektive obrazovanja, oni učenici koji

obrazovanje, a samim time i određene specifične predmete, smatraju važnim za vlastitu budućnost značajno su motiviraniji i ulažu mnogo više truda i napora od onih koji ne (Marušić, 2006), što je usko povezano s naknadnim izborom aktivnosti unutar tog područja, kao što je odabir smjera daljnjeg školovanja (Rovan i Jelić, 2008). Prema tome, učenici koji biologiju doživljavaju kao važan predmet za vlastitu budućnost, kako za svakodnevni život, tako i za budući odabir fakulteta, primjerice medicinu, bit će motiviraniji i ulagati više truda u učenje, sudjelovati na projektima vezanim uz biologiju, pohađati dodatnu nastavu i slično.

Samoefikasnost

Definicija očekivanja uspjeha značajno se preklapa s konstruktom samoefikasnosti kojeg je definirao Albert Bandura 1997. godine u okviru svoje socijalno-kognitivne teorije. Prema toj teoriji, samoefikasnost se definira kao procjena pojedinca o vlastitim sposobnostima organiziranja i izvršavanja akcija koje su potrebne za ostvarenje željenih ishoda (Bandura, 1997). Vjerovanja o samoefikasnosti formiraju se na osnovi prijašnjih iskustava osobe, opažanja uspješnosti drugih te na osnovi stavova i vjerovanja koje drugi ljudi daju o sposobnostima osobe, primjerice roditelji, skrbnici i druge bliske osobe (Reić Ercegovac i Koludrović, 2010). Ono što je važno naglasiti jest da je samoefikasnost vezana uz procjenu sposobnosti u specifičnoj situaciji, u određenom trenutku te se uvijek nanovo vrši u nekoj konkretnoj situaciji (Bandura, 2006; prema Rovan, Šimić i Pavlin-Bernardić, 2017).Situacijski određene percepcije samoefikasnosti važne su za konkretno prilagođavanje problemskim situacijama (Ratkajec Gašević, Dodig Hundrić i Mihić, 2016). Primijenivši to na školu, procjena samoefikasnosti vezana je uz svaki specifični predmet (samoefikasnost u biologiji) i upravo takva specifična mjera samoefikasnosti bolje predviđa učinak u konkretnom zadatku nego cjelokupni akademski angažman.

Prethodna istraživanja pokazuju da samoefikasnost, kako posredno, tako i neposredno, utječe na proces učenja i akademsko postignuće na način da poveća težnje učenika da postignu što bolji uspjeh (Pajares, 1996; Bandura, 1993, prema Reić Ercegovac i Koludrović, 2010). Samoefikasnost u prirodnim znanostima predstavlja značajan prediktor akademskog uspjeha u prirodnim znanostima, ali i odabira ciljeva vezanih uz prirodne znanosti kroz razvojnu dob učenika (odabir srednje škole ili fakulteta, odabir radnog mjesta) (Britner i Pajares, 2006). To upućuje da samoefikasnost može varirati između različitih obrazovnih područja na način da ju učenik može visoko percipirati u društvenim predmetima, a nisko u prirodnim predmetima i

obrnuto. Dakle, učenici koji percipiraju visoku samoefikasnost u nekom predmetu, imaju i veći interes za učenjem tog predmeta i postižu bolje rezultate nego u nekom drugom predmetu.

Uvjerenja o samoefikasnosti utječu na odabir ciljevima usmjerene aktivnosti, napor koji pojedinac ulaže u postizanju tih ciljeva te na količinu ustrajnosti u rješavanju problema kada naiđe na poteškoće (Bandura, 1991). One osobe koje imaju viši stupanj samoefikasnosti vjerojatnije će birati teže zadatke, ulagati više truda i duže ustrajati u rješavanju problema nego one koje imaju niži stupanj samoefikasnosti. Prema tome, u školskom kontekstu, ako učenik percipira da neće uspjeti u izvršavanju zadatka staničnih dioba na satu biologije jer mu je preteško ili vjeruje da ne raspolaže sposobnostima koje mu mogu pomoći u rješavanju zadatka, malo je vjerojatno da će uopće pokušati riješiti te neće ni biti ustrajan da pokuša riješiti problem na koji je naišao.

Koncept samoefikasnosti je široko primjenjiv jer se njime mogu objasniti različite odrednice ponašanja osobe te je u prethodnom primjeru povezan s postignućem koji se odnosi na *akademsku samoefikasnost.* Ona je usmjerena specifično na akademske zadatke i postizanje akademskih ciljeva, a sve se više proučava u posljednjih nekoliko godina (Đukić, Radusinović i Vukčević, 2013). Učenici koji imaju visoku akademsku samoefikasnost- probleme promatraju kao izazov, teže visokom akademskom postignuću i neuspjehe doživljavaju kao nedostatak znanja, a ne nedostatak sposobnosti (Bandura, 1993, prema Đukić i sur., 2013). Istraživanja koja su se bavila akademskom samoefikasnošću u specifičnim akademskim područjima su pokazala da se učenici procjenjuju efikasnijima upravo u području znanosti, tehnologije i matematike, odnosno u STEM području, dok učenice više u društvenom području (Bandura, 2006, prema Reić Ercegovac i Koludrović, 2010). Iako su utvrđene razlike u specifičnim područjima akademske samoefikasnosti, rezultati istraživanja ne pokazuju postojanje stvarnih razlika u postignućima u kojima postoji razlika u percipiranoj samoefikasnosti (Brindgeman i Wendler, 1991, prema Reić Ercegovac i Koludrović, 2010). Učenice se procjenjuju manje efikasnima u područjima i zanimanjima koju su tipično vezani uz muškarce za razliku od učenika koji se procjenjuju jednako efikasnima u svim zanimanjima, što bi se moglo povezati s time da su djevojke skromnije u procjeni vlastitih mogućnosti radi posljedica socijalizacijskih i tradicijskih činitelja (Reić Ercegovac i Koludrović, 2010).

Što se tiče povezanosti akademske samoefikasnosti i dobi, rezultati istraživanja nisu jednoznačni. Istraživanje provedeno na osnovnoškolcima pokazuje kako učenici 5. razreda procjenjuju svoju akademsku samoefikasnost višom od učenika 8. razreda (Nikčević-Milković, Jerković i Biljan, 2014), dok prema istraživanju Reić Ercegovac i Kaludrović (2010), nema

razlike u procjenjivanju akademske samoefikasnosti učenika od 1. do 4. razreda osnovne škole. Istraživanje provedeno na studentima koje je proučavalo odnos akademske samoefikasnosti vezane uz 2 biološka kolegija i dobi, pokazalo je da nema razlike između starijih i mlađih studenata, no oni studenti koji imaju više fakultetskog iskustva procjenjuju i višu razinu akademske samoefikasnosti u odnosu na one s manje iskustva te one koji su tek upisali fakultet (Witt-Rose, 2003). Istraživanje provedeno na populaciji studenata koji se bave kemijom kao prirodnom znanosti pokazalo je da oni studenti koji procjenjuju svoju samoefikasnost višom imaju više akademsko postignuće te ulažu više truda u učenje kemije, svoje postignuće pripisuju sposobnosti, a padove okruženju ili nedostatku napora (Tenaw, 2013). Slično istraživanje provedeno također na populaciji studenata proučavalo je odnos samoefikasnosti, motivacije, strategija učenja i akademskog postignuća te je pokazano da je samoefikasnost najsnažniji pozitivni prediktor koji ima izravni učinak, dok preostala tri djeluju neizravno na akademsko postignuće (Yusuf, 2011).

Strategije učenja

U psihologiji obrazovanja se tijekom posljednjih desetljeća javlja veliko zanimanje za samoregulaciju učenja čije definicije su mnogobrojne, no među njima postoji više sličnosti nego razlika. Najopćenitije se definira kao sustavni proces koji uključuje postavljanje osobnih ciljeva i usmjeravanje vlastitog ponašanja prema ostvarenju tih ciljeva (Lončarić, 2014). Razvijeni su mnogi modeli koji naglašavaju različite aspekte procesa samoregulacije učenja, a jedan od istaknutih modela ističe da uključuje emocionalno područje koje obuhvaća kontrolu napora oko akademskih zadataka te kognitivno područje, odnosno kognitivne i (meta)kognitivne strategije učenja (Pintrich i De Groot, 1990).

Strategije učenja definiraju se kao operacije koje učenik koristi kako bi si olakšao stjecanje, pohranu ili dosjećanje informacija (Oxford, 1990; prema Sorić, 2014). To su učenikove specifične akcije kako bi učenje bilo što lakše, zabavnije, učinkovitije i brže. Prema kognitivnom području koje obuhvaća strategije učenja, one se dijele na kognitivne i (meta)kognitivne (Garcia i Pintrich, 1994), a prema Lončariću (2014), strategije učenja dijele se na ciklus (meta)kognitivnih kontrola učenja, dubokog i površinskog kognitivnog procesiranja. Ciklus (meta)kognitivne kontrole učenja obuhvaća ponavljanje i uvježbavanje, kontrolu tijeka i ishod učenja. Ponavljanje i uvježbavanje se odnosi na usmjeravanje pozornosti na dobivenu informaciju i njezino zadržavanje u radnom pamćenju, dok se kontrola tijeka i ishoda učenja odnose na praćenje oscilacije pažnje, samoprovjeravanje upamćenog i praćenje

razumijevanja odgovaranjem na pitanja (Vizek Vidović i sur., 2014). Strategije dubokog kognitivnog procesiranja obuhvaćaju strategije *višeg reda* kao što su elaboracija, organizacija, primjena i kritičko mišljenje, dok strategije površinskog kognitivnog procesiranja podrazumijevaju strategije učenja napamet, bez puno napora i promišljanja o gradivu koje se uči i to su memoriranje i usmjerenost na minimalne zahtjeve (Lončarić, 2014). (Meta)kognitivna kontrola učenja je važna jer dovodi do konceptualnih promjena u procesu učenja što omogućuje zadržavanje informacija i njihovu daljnju primjenu (Georghiades, 2000; prema Vrdoljak i Vlahović-Štetić, 2018). Upotreba strategija dubokog kognitivnog procesiranja dovodi do razumijevanja sadržaja i do ishoda koji su afektivno zadovoljavajući učeniku jer potiču interes i pozitivne emocije vezane uz učenje, dok upotreba strategija površinskog kognitivnog procesiranja rezultira samo pamćenjem i ponavljanjem činjenica bez razumijevanja gradiva (Biggs, 1985; Coutinho i Neuman, 2008; prema Vrdoljak i Vlahović-Štetić, 2018). Učenje s razumijevanjem je poželjno radi mogućnosti primjene znanja u novim situacijama, kako tijekom procesa obrazovanja, tako i u svakodnevnom životu. Učenik koji upotrebljava strategije dubokog kognitivnog procesiranja puno čita, postavlja mnoga pitanja, raspravlja s drugim učenicima i profesorom, povezuje gradiva različitih predmeta, dok učenik koji upotrebljava strategije površinskog procesiranja pokušava samo zapamtiti ono što mora naučiti bez previše razmišljanja ili traženja poveznica između različitih zadataka ili predmeta (Vizek Vidović i sur., 2014).

Kako bi učenici bili što uspješniji u učenju, trebaju postaviti ciljeve i pronaći adekvatne strategije koje bi dovele do ostvarenja tih ciljeva uz što veće postignuće (Butler i Winne, 1995; prema Gucek i Labak, 2017). Istraživanja su pokazala da korištenje strategija učenja ima pozitivne učinke na proces učenja i akademsko postignuće, no upućuju i na problem nedovoljnog korištenja istih što se može pripisati nedostatku znanja o postojanju različitih strategija i načinu njihovog korištenja ili motivacijskim faktorima (Jakšić i Vizek Vidović, 2008). Jedan od motivacijskih faktora je i samoefikasnost, koja je osim s akademskim uspjehom povezana i s odabirom strategija učenja, posebice u području umjetnosti, matematike i prirodnih znanosti (Pajares, 2002). Prema tome, ako učenici procjenjuju svoje sposobnosti organizacije učenja i provedbu istog kao niske, ne koriste se previše strategijama učenja i to posebice ne onim *višeg reda* jer vjeruju da im one neće pomoći u tom području kad nemaju sposobnosti za to.

Kada učenici imaju efikasne strategije učenja i visoko procjenjuju svoje sposobnosti organizacije procesa učenja bit će uspješniji u učenju i postizat će bolje ocjene i akademski

uspjeh općenito (Zimmerman, 1995). Strategije učenja povezane su s akademskim uspjehom na način da bi strategije dubinskog kognitivnog procesiranja te (meta)kognitivne strategije trebale omogućiti bolje razumijevanje materijala, a time i veći uspjeh na testovima, odnosno bolju ocjenu i uspjeh općenito, dok je površinsko kognitivno procesiranje negativan prediktor ocjena jer učenici koji uče napamet i bez razumijevanja postižu lošiji akademski uspjeh (Vrdoljak i Vlahović-Štetić, 2018). Uspješniji učenici koriste veći broj različitih strategija učenja i to onih koje su povezane s dubinskim procesiranjem informacija za razliku od učenika koji postižu niži uspjeh (Vrkić i Vlahović-Štetić, 2013).

Odnosom akademskog uspjeha i strategija učenja bavila su se mnoga istraživanja. U istraživanjima učenika viših razreda osnovne škole, dobiveno je da se strategijama dubokog kognitivnog procesiranja više koriste učenici koji postižu vrlo dobar uspjeh, od onih koji postižu dobar uspjeh te da se učenici koji postižu dobar uspjeh najviše koriste upotrebom strategija površinskog kognitivnog procesiranja (Matić i Marušić, 2016; Nikčević-Milković, Jerković i Biljan, 2014; Rijavec, i sur., 1999). Učenici koji postižu odličan uspjeh češće koriste strategije ciklusa (meta)kognitivne kontrole učenja i oni će, u usporedbi s učenicima koji postižu vrlo dobar i dobar uspjeh, ulagati više kognitivnog napora prilikom učenja i manje površno pristupati učenju (Matić i Marušić, 2016). Istraživanje koje je ispitivalo odnos akademskog uspjeha i strategija učenja na učenicima srednje škole gimnazijskog usmjerenja i to na predmetu fizike, pokazalo je da oni učenici koji više koriste strategije ciklusa (meta)kognitivne kontrole učenja, postižu i bolje ocjene i obrnuto. Duboko kognitivno procesiranje nije bilo povezano s ocjenama i uspjehom, dok je površinsko kognitivno procesiranje bilo negativno povezano s uspjehom u fizici na način da što su više učili napamet i bez razumijevanja, učenici su postizali niži uspjeh u fizici (Vrdoljak i Vlahović-Štetić, 2018).

Strategije učenja povezane su i sa zadovoljstvom školom na način da veća uporaba strategija učenja dovodi do manjeg zadovoljstva školom i obrnuto (Nikčević-Milković i sur., 2014).

Što se tiče rodnih razlika u korištenju strategija učenja, istraživanje provedeno na srednjoškolcima, posebno se usmjeravajući na predmet biologije, pokazuje da učenice u odnosu na učenike češće koriste strategije ciklusa (meta)kognitivne kontrole učenja poput postavljanja pitanja, ponavljanja gradiva i provjeravanja znanja (Gucek i Labak, 2017). U istom tom istraživanju željelo se istražiti razlikuju li se učenici gimnazijskog usmjerenja od učenika strukovnog usmjerenja (ekološki tehničar) u navikama učenja biologije. Razlika je pronađena za strategije dubokog kognitivnog procesiranja te rezultati pokazuju kako učenici gimnazijskog

usmjerenja često koriste strategiju elaboracije za razliku od učenika strukovnog usmjerenja koji navode kako ju nikada ne koriste (Gucek i Labak, 2017).

Osim odnosa akademskog uspjeha, roda i korištenja strategija učenja, proučavan je i odnos dobi s vrstom strategija koje učenici upotrebljavaju. U istraživanju osnovnoškolaca pokazano je da učenici četvrtog i petog razred češće koriste (meta)kognitivne strategije učenja u odnosu na učenike osmog razreda (Brković, Keresteš i Kuterovac-Jagodić, 2012). Prema istraživanju Jandrić i suradnika (2018), u kojem su sudjelovali učenici petog i sedmog razreda, nije pokazana razlika među učenicima i učenicama u korištenju strategija učenja, niti s obzirom na razred koji pohađaju što se može pripisati tome da su se ispitivale strategije učenja općenito, a potiče se specifično usmjeravanje na pojedini predmet.

Prema Sorić (2014) motivacijska uvjerenja prepoznata su kao ključan dio samoregulacije učenja, a samim time i strategija učenja jer određuju kada, zašto i na koji način će se učenici uključiti u proces učenja. Upravo su konstrukti iz već spomenute *Teorije očekivanja i vrijednosti* određeni kao najvažniji motivacijski koncepti u samoregulaciji učenja (Pintrich, 2003; prema Sorić, 2014) te se javlja potreba za istraživanjem njihovog, ionako nedovoljno istraženog odnosa. Iako je prema istraživanju Rijavec i suradnika (1999), pokazano da postoji pozitivna povezanost između samoefikasnosti i korištenja strategija učenja, treba se specifično istražiti na koji način je taj konstrukt povezan s određenom vrstom strategija učenja zajedno s konstruktom subjektivnih vrijednosti i to samo prilikom učenja specifičnog predmeta biologije. Pretpostavlja se da će učenik upotrebljavati strategiju *višeg reda* prilikom učinkovitijeg i bržeg učenja gradiva biologije ako ima više procijenjenu samoefikasnost i subjektivnu vrijednost zadatka i obrnuto.

Uključenost

Jedan od ključnih čimbenika u postizanju očekivanih akademskih ishoda koji se sve više istražuje u posljednja dva desetljeća jest i uključenost (Pavlin-Bernardić, Putarek, Rovan, Petričević i Vlahović-Štetić, 2017). Interes je sve veći budući da mnogi smatraju da bolje razumijevanje uključenosti može pomoći ne samo unapređenju akademskih ishoda, već i u smanjivanju nepoželjnog akademskog ponašanja, nezainteresiranosti učenika te postizanju slabijeg uspjeha (Christenson, Reschly i Wylie, 2012). Autori različito definiraju konstrukt uključenosti kao i njezine dimenzije, no najjednostavnije je definirati kao aktivno sudjelovanje u školskim aktivnostima te posvećenost obrazovnim ciljevima (Christenson i sur., 2012).

Uključenost se može definirati i kao količina fizičke i psihičke energije koju učenik ili student ulaže u svoj obrazovni proces te se javlja kao kontinuum kojim razlikujemo dva kraja – uključenost i neuključenost (Astin, 1999). Prema tome, učenik za kojeg možemo reći da je *uključen* u nastavu je onaj koji ulaže mnogo energije u sam proces učenja, aktivno sudjeluje u brojnim aktivnostima i raspravama vezanim u školu te je u čestom kontaktu s ostalim učenicima ili kolegama i profesorima. Onaj učenik koji često izostaje s nastave, zanemaruje svoje školske obaveze, nema česti kontakt s drugim učenicima i profesorima te se ne uključuje u dodatne školske aktivnosti je onaj za kojeg kažemo da je *neuključen* (Bektić Mihaljević, 2016). Uključenost također poput samoefikasnosti može varirati između različitih obrazovnih područja, primjerice na način da učenici mogu biti *uključeni* na nastavi prirodnih predmeta, a biti *neuključeni* i nezainteresirani na nastavi društvenih predmeta.

Iako postoje različita mišljenja o definiciji i broju dimenzija za koje neki autori navode da su dvije, neki tri ili čak četiri, većina se istraživača slaže da je uključenost složen konstrukt (Fredricks, Blumenfeld i Paris, 2004). Najčešće je istraživan trofaktorski model, prema kojem se uključenost sastoji od tri dimenzije, a to su bihevioralna, emocionalna i kognitivna uključenost (Fredricks i sur., 2004), a u ovom će se istraživanju istraživati samo dvije dimenzije-bihevioralna i kognitivna.

Bihevioralna uključenost podrazumijeva nekoliko ponašanja kao što su poštivanje pravila u razredu, praćenje uputa, ulaganje truda, postavljanje pitanja te obraćanje pažnje, usmjerenost na gradivo i upornost (Fredricks i sur., 2004). Osim toga važno je spomenuti ponašanja koja uključuju sudjelovanje u raspravama u razredu tijekom satova te drugim školskim i društvenim aktivnostima poput odlazaka na terensku nastavu i pohađanje dopunske ili dodatne nastave (Rovan, i sur., 2017). Druga je dimenzija emocionalna uključenost, a obuhvaća sve pozitivne (ponos, zadovoljstvo) i negativne (anksioznost, frustracija) emocije koje učenici mogu doživjeti tijekom nastave u razredu ili učenja (Kong, Wong i Lam, 2003). Posljednja dimenzija uključenosti jest kognitivna uključenost koja se najšire može definirati količinom psihološkog ulaganja truda u učenje i razumijevanje složenih ideja te na primjenu strategija učenja (Fredricks i sur., 2004). Također podrazumijeva način na koji učenici primaju informacije, pohranjuju ih u svojem paćenju te koriste u razmišljanju o problemu i njegovom savladavanju (Kong i sur., 2003). Prema Kongu i suradnicima (2003), postoji nekoliko pokazatelja kognitivne uključenosti, a to su korištenje površinskih strategija (pamćenje, vježbanje), korištenje dubokih strategija (razumijevanje, povezivanje, sažimanje) te oslanjanje na roditelje i profesore.

Zainteresiranost za istraživanje uključenosti leži u tome da je vezana i uz pojam motivacije. Uključenost predstavlja manifestaciju motivacije pri čemu je motivacija namjera za uključivanje u aktivnost, a uključenost označava uključivanje u samu akciju (Reeve, 2012). Važna je i za školski uspjeh jer sve tri njezine dimenzije predviđaju bolji školski uspjeh (Fredricks i sur., 2004). Bihevioralna uključenost je negativno povezana sa stopom odustajanja od školovanja (Archambault, Janosz, Fallu i Pagani, 2009; prema Putarek, Rovan i Vlahović-Štetić, 2016), a njezina korisnost pronađena je i u okviru promicanja završetka školovanja posebno za apatične učenike koji ne vide vrijednost škole i koji su obeshrabreni doživjevši neku frustraciju (Appleton, Christenson i Furlong, 2008). Bihevioralna uključenost zajedno s emocionalnom predviđa manju vjerojatnost zlouporabe sredstava ovisnosti i sudjelovanja u delikventnim ponašanjima (Ladd i Dinella, 2009, prema Putarek i sur., 2016).

Proučavan je i odnos uključenosti, roda i ocjena. Istraživanje provedeno na učenicima 12 različitih zemalja pokazalo je kako je rod značajan prediktor uključenosti na način da su djevojke više uključene od dječaka (Lam i sur., 2016). Da su djevojke više uključene u nastavu od dječaka, pokazalo je i istraživanje Reyesa i suradnika (2012), čiji rezultati još ukazuju na pozitivnu povezanost ocjena s uključenošću na način da oni učenici koji imaju bolje ocjene, više se uključuju na nastavu i obrnuto.

U posljednje vrijeme je uočen problem smanjene uključenosti učenika na nastavi upravo predmeta STEM područja (Bøe, Henriksen, Lyons i Schreiner, 2011). Kako bi učenici stekli sva znanja i usvojili sve vještine koje su im potrebne u daljnjem profesionalnom razvoju, važno im je osvijestiti vrijednost tog područja i ustrajanje u savladavanju zadataka koje ono nosi (Putarek i sur., 2016). Nalazi istraživanja koja su se bavila prediktorima uključenosti upravo na STEM području pokazuju da su samoefikasnost i samoefikasnost u samoregulaciji značajni pozitivni prediktori i bihevioralne i kognitivne uključenosti u nastavu fizike (Boljkovac, 2018), zajedno sa subjektivnim vrijednostima u nastavi kemije (Rovan i sur., 2017). Slično je i dobiveno u istraživanju Bektić Mihaljević (2016) u kojem samoefikasnost i samoefikasnost u samoregulaciji pozitivno predviđaju sve dimenzije uključenosti u nastavi biologije pri čemu je samoefikasnost najbolji prediktor bihevioralne uključenosti, a vrijednosti kognitivne uključenosti.

Ciljevi i problemi istraživanja

Cilj ovog istraživanja jest ispitati odnos motivacijskih uvjerenja (samoefikasnost i subjektivna vrijednost) sa strategijama učenja i uključenosti učenika u nastavu biologije. S obzirom na cilj istraživanja formulirani su sljedeći problemi:

Ispitati doprinos samoefikasnosti i subjektivne vrijednosti biologije u objašnjavanju individualnih razlika u uporabi različitih strategija učenja biologije.

Ispitati doprinos samoefikasnosti i subjektivne vrijednosti biologije u objašnjavanju individualnih razlika u uključenosti u nastavu biologije.

Na osnovi dosadašnjih istraživanja hipoteze su slijedeće:

H1 Samoefikasnost i subjektivna vrijednost biologije pozitivno će predviđati uključenost učenika u nastavu biologije (bihevioralnu uključenost u nastavu biologije, kognitivnu uključenost u nastavu biologije)

H2 Samoefikasnost i subjektivna vrijednost biologije pozitivno će predviđati uporabu strategija ciklusa (meta)kognitivne kontrole učenja i dubokog kognitivnog procesiranja te negativno uporabu strategija površinskog kognitivnog procesiranje prilikom učenja biologije

Metoda

Sudionici

U ovom istraživanju je sudjelovalo ukupno 199 učenika iz tri opće gimnazije na području Krapinsko-zagorske županije. Uzorak se sastojao od učenika drugih (N=107, 53.8%) i trećih razreda (N=90, 45.2%) od čega je bilo 64 mladića (32.2%) i 135 djevojaka (67.8%). Sudjelovalo je 3 učenika u dobi od 15 godina (1.5%), 100 učenika u dobi od 16 godina (50.3%), 95 učenika u dobi od 17 godina (47.7%) i 1 učenik u dobi od 18 godina (0.5%). Prosječna dob sudionika je bila je M=16.47 godina uz SD=0.539.

Postupak

U prvoj fazi istraživanja kontaktirane su školske psihologinje svih triju škola, prvo telefonskim putem, a zatim je e-mailom poslana sva potrebna dokumentacija. Na fakultetu su se zatražili službeni obrasci u kojima je pisalo o svrsi istraživanja te o anonimnosti podataka s naglaskom da će biti korišteni samo u svrhu izrade diplomskom rada te su poslani svakoj školi.

Radi *Opće uredbe o zaštiti podataka (GDPR)* koja se primjenjuje od 25. svibnja 2018. godine, svaka organizacija mora znati za što se koriste osobni podaci njihovih korisnika te u ovom slučaju obavijestiti i roditelje učenika, stoga su zatražili da im se dostave i suglasnosti za roditelje. Nakon službenog odobrenja ravnatelja svih triju škola, osobno se otišlo do srednjih škola i dostavile su se suglasnosti za roditelje kako bi i oni bili obaviješteni o provedbi istraživanja te da se dobije i njihov službeni pristanak da njihovo dijete može sudjelovati u istraživanju. Od roditelja se tražio pasivni pristanak, odnosno da potpisani pristanak vrate u školu ako ne žele da njihovo dijete sudjeluje u istraživanju. U jednoj su se srednjoj školi zajedno sa školskom psihologinjom podijelile suglasnosti učenicima, dok su u druge dvije srednje škole, školske psihologinje to podijelile same. Nakon otprilike tjedan dana, školske psihologinje su obavijestile kako ni jedan roditelj nije potpisao, što znači da su svi bili suglasni te su se dogovorili termini provođenja istraživanja koji su bili kroz svibanj 2019. godine. Ispunjavanje upitnika provodilo se grupno u razrednim odjeljenjima svake škole, uz prisutnost razrednika, predmetnog nastavnika ili školske psihologinje. Učenicima se prvo kratko objasnila svrha istraživanja, istaknulo se kako je ispunjavanje u potpunosti anonimno i dobrovoljno te da u bilo kojem trenutku smiju odustati od istraživanja bez ikakvih posljedica. Nakon toga su im podijeljeni upitnici gdje su pročitavši prvu stranu, ujedno dali i sami svoj pristanak na sudjelovanje u istraživanju. Naglašeno im je da će se pri izvještavanju o rezultatima istraživanja koristiti samo podaci za čitavu grupu sudionika te da se neće objavljivati individualni odgovori sudionika. Vrijeme ispunjavanja upitnika u prosjeku je trajalo 15-ak minuta.

Mjerni instrumenti

Upitnik se sastojao od skala za mjerenje samoefikasnosti, uključenosti u učenje i nastavu biologije, vrijednosti te strategija učenja. Osim navedenih skala, na kraju upitnika se od učenika tražilo da navedu podatke o dobi, rodu, razredu kojeg pohađaju, prosjek ocjena na kraju prošle školske godine i ocjenu iz biologije, zadovoljstvo tom ocjenom, očekivanu ocjenu iz biologije na kraju tekuće školske godine, pohađaju li ili su prije pohađali dodatnu nastavu iz biologije te hoće li izabrati biologiju kao izborni predmet na državnoj maturi (Da/Možda/Ne).

Skala samoefikasnosti (Rovan, 2011) ispituje samoprocjenu vlastite kompetentnosti u području biologije te se sastoji od 7 čestica (npr. „Siguran/na sam da mogu dobro razumjeti pojmove koji se uče na biologiji“). Tvrdnje se procjenjuju na skali od 1 (uopće se ne slažem) do 7 (potpuno se slažem). Ukupni rezultat izražava se kao prosjek odgovora na svim tvrdnjama. U ovom istraživanju pouzdanost je izražena Cronbachovim koeficijentom i iznosi .89.

Skala uključenosti u učenje i nastavu biologije ispituje trud i napor uložen u savladavanje obaveza i gradiva vezanih uz biologiju. Korištena skala prilagođena je na temelju *Skale za mjerenje uključenosti u učenje fizike* koju su konstruirale i validirale Pavlin-Bernardić i suradnice (2017), na način da su čestice izmijenjene tako da se odnose na biologiju. Sastoji se od 23 tvrdnje, ali u ovom istraživanju su uključene samo čestice koje mjere kognitivnu i bihevioralnu uključenost.“). Tvrdnje se procjenjuju na skali od 1 (ne slažem se) do 5 (slažem se). Subskala bihevioralne uključenosti sastoji se od 8 čestica, rekodirane su 3 čestice te je operacionalizirana kao uložen trud u izvršavanje obaveza vezanih uz nastavu biologije (npr. „Redovito učim biologiju“). Subskala kognitivne uključenosti sastoji se od 5 čestica i operacionalizirana je kao kognitivni napor koji učenici ulažu u savladavanje gradiva iz biologije (npr. „Postavljam sam sebi pitanja iz biologije kako bih bio siguran da dobro razumijem gradivo“). Ukupni rezultat na navedenim podljestvicama računa se kao prosjek odgovora na svim česticama. Viši rezultat na sve tri skale predstavlja veću uključenost u učenje biologije. Pouzdanost izračunata Cronbach α koeficijentom za bihevioralnu uključenost u ovom istraživanju iznosi .92, a za kognitivnu uključenost .73 što je prihvatljivo.

Skala vrijednosti (Wigfield i Eccles, 2000) namijenjena je mjerenju subjektivnih vrijednosti koje učenici pridaju biologiji, a kreirana je prema *Teoriji očekivanja i vrijednosti*. Skala je konstruirana u sklopu projekta *Povezanost subjektivne vrijednosti učenja prirodnih znanosti s obrazovnim ishodima* koji su provodile Vlahović-Štetić i suradnice. Sastoji se od 13 tvrdnji, pri čemu se na komponentu korisnosti odnose četiri tvrdnje (npr. „Sadržaje koje učim na biologiji moći ću primijeniti u svakodnevnom životu“), na interes pet tvrdnji („Zanimaju me sadržaji koje učim na biologiji“), a na važnost četiri tvrdnje („Važno mi je dobro poznavati prirodu oko nas“). Odgovori se daju na skali Likertovog tipa u rasponu od 1 (ne slažem se) do 5 (slažem se). Dvije čestice („Dosadno mi je učiti gradivo iz biologije.“ i „Mislim da je sadržaj koji se obrađuje u sklopu nastave biologije dosadan.“) su rekodirane. Kako je u ovom istraživanju, kao i u istraživanju Bektić Mihaljević (2016) dobivena jednofaktorska struktura skale, u provedenim analizama u obzir je uzeta samo jedna vrijednost, izračunata kao prosjek vrijednosti svih zaokruženih tvrdnji. Pouzdanost cijele skale izražena je Cronbachovim α koeficijentom koji u ovom istraživanju iznosi .93.

Skala strategija učenja (Lončarić, 2014) ispituje na koji način učenici uče gradivo biologije, a sastoji se od tri subskale: ciklusa (meta)kognitivne kontrole učenja, dubokoga kognitivnog procesiranja i površinskoga kognitivnog procesiranja. Sastoji se od ukupno 39 čestica. Ciklus (meta)kognitivne kontrole učenja odnosi se na 11 čestica, od čega se 4 odnose

na ponavljanje i uvježbavanje („Ponavljam gradivo dok ga ne naučim i uvježbam izvođenje zadataka više puta dok ne budem brz/brza i točan/točna.“) te 7 njih na kontrolu tijeka i ishode učenja („Nakon učenja provjerim svoje znanje i razumijevanje gradiva.“). Ciklus dubokog kognitivnog procesiranja obuhvaća ukupno 20 čestica, od čega se 4 čestice odnose na elaboraciju („Kada god je to moguće, pokušavam povezati gradivo koje učim s onim što sam naučio na drugim predmetima ili što sam saznao od drugih.“), 7 čestica koje se odnose na organizaciju („Velika gradiva pokušavam podijeliti u više manjih cjelina koje su razumljive i smislene.“), 4 čestice koje se odnose na primjenu („Mnoge stvari lakše naučim ako ih nekako zamislim ili predočim.“) te 5 čestica koje se odnose na kritičko mišljenje („Dok učim, uvijek imam na umu da svako objašnjenje ima prednosti i nedostatke.“). Posljednji ciklus površinskog kognitivnog procesiranja obuhvaća ukupno 8 čestica, od čega se 4 odnose na usmjerenost na minimalne zahtjeve („Učim samo onoliko koliko je potrebno za pozitivnu ocjenu.“) te 4 na memoriranje („Gradivo uglavnom učim doslovno i napamet.“). Odgovori se daju na skali od 5 stupnjeva pomoću koje procjenjuju u kojoj mjeri koriste strategiju učenja navedenu u pojedinoj čestici (od 1 - tako nisam nikada radio/la do 5 - uvijek tako radim). Ukupni rezultat dobiva se zbrajanjem čestica na pojedinoj subskali. Pouzdanost skala izražena je Cronbachovim α koeficijentom koji u ovom istraživanju iznosi .87 za ciklus (meta)kognitivnih kontrola učenja i dubokog kognitivnog procesiranja te .73 za ciklus površinskog kognitivnog procesiranja.

Rezultati

Kako bi se ispitao doprinos samoefikasnosti i subjektivne vrijednosti biologije u objašnjavanju individualnih razlika u uključenosti u nastavu biologije te korištenju strategija učenja pri savladavanju gradiva, prvo je provedena preliminarna obrada rezultata. Zatim se utvrđivala povezanost korištenih prediktorskih i kriterijskih varijabli i na kraju su provođene hijerarhijske regresijske analize kako bi se utvrdio zaseban doprinos pojedinih prediktorskih varijabli u objašnjavanju varijance kriterijskih varijabli.

Tablica 1. *Rezultati deskriptivne analize za sve varijable korištene u istraživanju (N=199)*

Varijabla	*M*	*SD*	*Min*	*Max*	*K-S*
Samoefikasnost	4.97	1.06	2.14	7.00	0.10**
Subjektivna vrijednost biologije	3.40	0.86	1.15	5.00	0.10**
Prosjek ocjena	4.28	0.47	1.86	5.00	0.10**
Bihevioralna uključenosti	3.05	0.99	1.00	5.00	0.74**
Kognitivna uključenost	3.20	0.84	1.20	4.80	0.21**
Strategije ciklusa (meta)kognitivne kontrole učenja	40.76	7.73	14.00	55.00	0.144**
Strategije dubokog kognitivnog procesiranja	69.31	12.05	35.00	97.00	0.058
Strategije površinskog kognitivnog procesiranja	19.72	5.33	8.00	37.00	0.65**

Napomena: *K-S* – z-vrijednost Kolmogorov-Smirnovljevog testa normaliteta distribucije; $^{**}p < .01$

U preliminarnoj obradi rezultata izračunati su koeficijenti pouzdanosti unutarnje konzistencije. Za sve korištene varijable izračunati su i deskriptivni podaci te su također ispitani normaliteti distribucija pomoću Kolmogorov-Smirnovog testa što je sve prikazano u Tablici 1. U navedenoj tablici uočavamo kako postoji odstupanje svih varijabli osim varijable *strategije dubokog kognitivnog procesiranja* od normalne distribucije. Unatoč odstupanju moguće je provoditi daljnje analize budući da je normalna distribucija reziduala nakon provedbe regresijskih analiza pokazala da odstupanja nisu prevelika.

Tablica 2. *Pearsonovi koeficijenti korelacije za varijable korištene u istraživanju (N=199)*

Varijable	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.
1. Spol	_									
2. Dob	.02	_								
3. Prosjek ocjena	.39**	-.18*	_							
4. Bihevioralna uključenost	.24**	.06	.15*	_						
5. Kognitivna uključenost	.32**	.04	.29**	.54**	_					
6. Strategije (meta)kognitivna kontrole učenja	.34**	-.01	.32**	.47**	.62**	_				
7. Strategije dubokog kognitivnog procesiranja	.25**	-.12	.07	.21**	.43**	.37**	_			
8. Strategije površinskog kognitivnog procesiranja	-.10	.07	-.28**	-.41**	-.29**	-.23**	-.26**	_		
9. Samoefikasnost	.17*	.10	.28**	-.29**	.47**	.34**	.28**	-.42**	_	
10. Subjektivna vrijednost biologije	.35**	.10	.31**	.48**	.62**	.45**	.40**	-.48**	.64**	_

Kako bi se utvrdila povezanost motivacijskih uvjerenja s dimenzijama uključenosti učenika na nastavi biologije i sa strategijama učenja koje koriste za savladavanje gradiva u biologiji, izračunati su Pearsonovi koeficijenti korelacije, koji su navedeni u Tablici 2. Uz motivacijska uvjerenja, kao prediktore su dodatno uvršteni spol, dob te prosjek ocjena na kraju prošle školske godine. Spol korelira značajno, ali nisko s bihevioralnom i kognitivnom uključenošću. Učenice su više kognitivno i bihevioralno uključene u nastavu biologije u odnosu na učenike. Osim toga, spol značajno korelira s dvije kategorije strategija učenja (strategije ciklusa (meta)kognitivne kontrole učenja i dubokog kognitivnog procesiranja) i korelacija između njih je umjerena. Učenice više koriste strategije ciklusa (meta)kognitivne kontrole učenja i dubokog kognitivnog procesiranja u odnosu na učenike. Spol značajno korelira sa subjektivnim vrijednostima biologije i samoefikasnosti pri čemu učenice pokazuju više razinu od učenika.

Prosjek ocjena na kraju školske godine značajno i nisko korelira sa svime osim sa strategijama dubokog površinskog procesiranja.

Što se tiče dimenzija uključenosti, one međusobno značajno i umjereno koreliraju. Koreliraju značajno i sa sve tri kategorije strategija učenja i motivacijskim uvjerenjima. Kognitivna uključenost najsnažnije korelira sa strategijama ciklusa (meta)kognitivne kontrole učenja, dok bihevioralna osim s kognitivnom uključenošću, najsnažnije korelira sa subjektivnim vrijednosti biologije. Prema tome, učenici koji smatraju biologiju važnom, više će se uključivati na satu biologije, sudjelovati u raspravama i slično. Od značajnih korelacija, bihevioralna uključenost najniže korelira s prosjekom ocjena na kraju prošle školske godine, dok kognitivna uključenost sa strategijama dubokog kognitivnog procesiranja.

Strategije ciklusa (meta)kognitivne kontrole učenja najsnažnije koreliraju s kognitivnom uključenošću, a najniže sa strategijama površinskog kognitivnog procesiranja. Strategije dubokog kognitivnog procesiranja najsnažnije koreliraju sa strategijama ciklusa (meta)kognitivne kontrole učenja, a najniže s bihevioralnom uključenošću, dok strategije površinskog kognitivnog procesiranja najsnažnije koreliraju s bihevioralnom uključenošću, a najniže s prosjekom ocjena na kraju prošle školske godine.

Samoefikasnost i subjektivna vrijednost biologije koreliraju najsnažnije međusobno, a najniže s prosjekom ocjena na kraju prošle školske godine.

Kako bi se odgovorilo na postavljena istraživačka pitanja, korištena je hijerarhijska regresijska analiza. Prediktorski skup varijabli uključuje spol, dob, prosjek na kraju prošle školske godine, samoefikasnost i subjektivna vrijednost biologije, dok su kriterijske varijable kognitivna i bihevioralna uključenost na nastavi te tri kategorije strategija učenja: strategije ciklusa (meta)kognitivne kontrole učenja te strategije dubokog i površinskog kognitivnog procesiranja. Hijerarhijska regresijska analiza provedena je zasebno za svaki od pet navedenih kriterija koji su uključeni u istraživanje.

Tablica 3. *Hijerarhijska regresijska analiza s mjerama sociodemografskih podataka i motivacijskih uvjerenja kao prediktorima bihevioralne uključenosti u nastavu biologije (N =199)*

	1. korak *β*	2. korak *β*	3. korak *β*
Spol	.241**	.207**	.090
Dob	.058	.074	.013
Prosjek ocjena na kraju prošle školske godine		.086	-.017
Samoefikasnost			-.020
Subjektivna vrijednost biologije			.465**
R	.249**	.261	.487**
R^2	.062	.068	.237
ΔR^2	.062**	.006	.169**

Napomena: ** $p < .01$, * $p < .05$

Prva regresijska analiza provedena je u tri koraka s bihevioralnom uključenošću kao kriterijem (Tablica 3). U prvom koraku uvršteni su spol i dob kao kontrolne varijable, u drugom koraku dodan je prosjek ocjena na kraju prošle školske godine te su u trećem koraku dodana motivacijska uvjerenja - samoefikasnost i subjektivna vrijednost biologije. U prvom koraku objašnjeno je 6.2% varijance bihevioralne uključenosti u učenje biologije pri čemu se samo spol pokazao kao značajan samostalan prediktor. U drugom koraku uvršten je prosjek ocjena na kraju prošle školske godine, no nije se pokazao kao značajan prediktor te pomoću njega nije objašnjen značajan dio varijance bihevioralne uključenosti (svega 0.6%). Spol je i u drugom koraku značajan samostalan prediktor, no nije objasnio značajan dio varijance kriterija. Dodavanjem motivacijskih uvjerenja u trećem koraku objašnjeno je dodatnih 16.9% varijance bihevioralne uključenosti u učenje biologije. Subjektivna vrijednost biologije se pokazala kao značajan samostalan prediktor, a spol prestaje biti značajan prediktor u trećem, zadnjem koraku. Korištenim skupom podataka, objašnjeno je ukupno 23.7% varijance bihevioralne uključenosti učenika u nastavu biologije. Kao najsnažniji prediktor bihevioralne uključenosti pokazala se subjektivna vrijednost biologije. Prema tome, učenici kojima je biologija subjektivno vrijedna,

više se bihevioralno uključuju u nastavu biologije (češće se javljaju na satu, pažljiviji su, ulažu više truda u rješavanje zadanih zadataka).

Tablica 4. *Hijerarhijska regresijska analiza s mjerama sociodemografskih podataka i motivacijskih uvjerenja kao prediktorima kognitivne uključenosti u učenje biologije (N = 199)*

	1. korak *β*	2. korak *β*	3. korak *β*
Spol	.322**	.245**	.115
Dob	.031	.067	-.019
Prosjek ocjena na kraju prošle školske godine		.194**	.044
Samoefikasnost			.125
Subjektivna vrijednost biologije			.488**
R	.324**	.368**	.639**
R^2	.105	.136	.409
ΔR^2	.105**	.030**	.273**

Napomena: ** $p < .01$, * $p < .05$

Druga hijerarhijska analiza ispitivala je doprinos prediktorskih varijabli u objašnjenju kriterijske varijable kognitivne uključenosti u nastavu biologije (Tablica 4). U prvom koraku objašnjeno je 10.5% varijance kognitivne uključenosti u nastavu biologije pri čemu se samo spol pokazao značajnim samostalnim prediktorom. U drugom koraku dodan je prosjek ocjena na kraju školske godine, koji je kao i spol značajan samostalni prediktor te je objašnjeno dodatnih 3% varijance kriterija. U trećem koraku objašnjeno je dodatnih 27.3% varijance kognitivne uključenosti u nastavu biologije pri čemu je samo subjektivna vrijednost biologije samostalan značajan prediktor, dok samoefikasnost kao i kod bihevioralne uključenosti nije. U istom tom koraku spol prestaje biti samostalan značajan prediktor. Skup prediktora ukupno doprinosi objašnjenju 40.9% varijance kognitivne uključenosti. Subjektivna vrijednost biologije ponovno je najsnažniji prediktor što znači da oni učenici kojima je biologija subjektivno vrijedna, ulažu više truda i energije u učenje i savladavanje složenih ideja, odnosno više su kognitivno uključeni u nastavu biologije od onih učenika kojima biologija kao predmet nije subjektivno vrijedna.

Tablica 5. *Hijerarhijska regresijska analiza s mjerama sociodemografskih podataka i motivacijskih uvjerenja kao prediktorima strategija ciklusa (meta)kognitivne kontrole učenja (N = 199)*

	1. korak *β*	2. korak *β*	3. korak *β*
Spol	.341**	.251**	.172**
Dob	-.022	.020	-.033
Prosjek ocjena na kraju prošle školske godine		.225**	.132
Samoefikasnost			.086
Subjektivna vrijednost biologije			.292**
R	.341**	.396**	.510**
R^2	.116	.157	.260
ΔR^2	.116**	.041**	.103**

Napomena: ** $p < .01$, * $p < .05$

U trećoj hijerarhijskoj analizi uvrštene su strategije ciklusa (meta)kognitivne kontrole učenja u biologiji kao kriterijska varijabla (Tablica 5). U prvom koraku samo je spol značajan samostalan prediktor i objašnjeno je 11.6% varijance kriterija. Kad se u drugom koraku doda prosjek ocjena na kraju prošle školske godine, objašnjavanja se dodatnih 4.1% varijance strategija (meta)kognitivnih kontrola učenja. U drugom koraku je uz spol i prosjek značajan samostalan prediktor. Kada se u analizu dodaju motivacijska uvjerenja, objašnjava se još dodatnih 10.3% varijance kriterija. U trećem koraku, prosjek ocjena na kraju prošle školske godine prestaje biti značajan samostalan prediktor. Korištenim skupom prediktora objašnjeno je ukupno 26% varijance kriterijske varijable. Spol je kroz sva tri koraka pokazan kao značajan samostalan prediktor te je i najsnažniji samostalni prediktor strategija ciklusa (meta)kognitivne kontrole učenja iz čega se može zaključiti kako učenice više u odnosu na učenike koriste navedene strategije učenja prilikom stjecanja, pohranjivanja ili dosjećanja informacija gradiva biologije.

Tablica 6. *Hijerarhijska regresijska analiza s mjerama sociodemografskih podataka i motivacijskih uvjerenja kao prediktorima strategija dubokog kognitivnog procesiranja (N = 199)*

	1. korak *β*	2. korak *β*	3. korak *β*
Spol	.255**	.281**	.189**
Dob	-.123	-.135	-.197**
Prosjek ocjena na kraju prošle školske godine		-.066	-.174*
Samoefikasnost			.100
Subjektivna vrijednost biologije			.343**
R	.280**	.286	.473**
R^2	.079	.082	.224
ΔR^2	.079**	.004	.142**

Napomena: ** $p < .01$, * $p < .05$

U tablici 6 prikazani su rezultati četvrte hijerarhijske regresijske analize sa strategijama dubokog kognitivnog procesiranja kao kriterijskom varijablom (Tablica 6). Prvim korakom objašnjeno je 7.9% varijance kriterija, pri čemu se spol pokazuje kao značajan samostalan prediktor. Uvrštavanjem prosjeka na kraju prošle školske godine ne objašnjava se dodatni značajni dio varijance kriterija (svega 0.4% varijance) niti se taj prediktor ne izdvaja kao samostalan značajan, već samo spol ostaje značajan kao i u prvom koraku. U posljednjem, trećem koraku se objašnjava dodatnih 14.2% varijance kriterija pomoću motivacijskih uvjerenja. U tom koraku su značajni svi prediktori osim samoefikasnosti. Subjektivna vrijednost biologije se ponovno pokazala kao najsnažniji prediktor i strategija dubokog kognitivnog procesiranja. Zadanim skupom prediktora objašnjeno je ukupno 22.4% varijance kriterija. Spol je značajan samostalan prediktor u sva tri koraka iz čega se može zaključiti kako učenice više u odnosu na učenike koriste strategije dubokog kognitivnog procesiranja u biologiji.

Tablica 7. *Hijerarhijska regresijska analiza s mjerama sociodemografskih podataka i motivacijskih uvjerenja kao prediktorima strategija površinskog kognitivnog procesiranja (N = 199)*

	1. korak *β*	2. korak *β*	3. korak *β*
Spol	-.102	.021	.107
Dob	-.065	-.123	-.054
Prosjek ocjena na kraju prošle školske godine		-.308**	-.184**
Samoefikasnost			-.193**
Vrijednost biologije			-.299**
R	.122	.303**	.509**
R^2	.015	.092	.259
ΔR^2	.015	.077**	.167**

Napomena: ** $p < .01$, * $p < .05$

U posljednjoj hijerarhijskoj analizi, strategije površinskog kognitivnog procesiranja uvrštene se kao kriterijska varijabla (Tablica 7). U prvom koraku nije se objasnio značajan dio varijance te se ni spol ni dob nisu pokazali kao značajni samostalni prediktori. Unošenjem prosjeka ocjena na kraju prošle školske godine objašnjava se 7.7% varijance kriterija te se taj prediktor pokazuje kao značajan negativan samostalan prediktor. U trećem koraku, nakon što se unesu motivacijska uvjerenja, objašnjeno je dodatnih 16.7% varijance strategija površinskog kognitivnog procesiranja pri čemu prosjek ocjena ostaje značajan prediktor uz značajna oba prediktora koja predstavljaju motivacijska uvjerenja (samoefikasnost i subjektivna vrijednost biologije). Skupom prediktora objašnjeno je ukupno 25.9% ukupne varijance kriterija. Kao najsnažniji prediktor ističe se prosjek ocjena na kraju prošle školske godine koji je značajan i

negativan prediktor iz čega se može zaključiti da što učenici imaju viši prosjek, manje su skloni koristiti strategije površinskog kognitivnog procesiranja i obrnuto. Spol nije značajan prediktor ni u jednom od tri koraka, no to je bilo za očekivati prema rezultatima korelacija i rezultatima prethodnih istraživanja u kojima se također spol nije istaknuo kao značajan prediktor.

Rasprava

Cilj ovog istraživanja bio je ispitati odnos motivacijskih uvjerenja (samoefikasnost i subjektivna vrijednost) sa strategijama učenja i uključenošću učenika u učenje i nastavu biologije.

Analizirajući bihevioralnu uključenost kao kriterij, objašnjeno je ukupno 23.7% varijance. Spol se pokazao značajnim prediktorom u prvom i drugom koraku na način da su učenice više bihevioralno uključene u nastavu biologije u odnosu na učenike. To je u skladu s rezultatima istraživanja Lama i suradnika (2016) te Reyesa i suradnika (2012), koji pokazuju da su djevojke više uključene u nastavu bez obzira na ostale okolinske i osobne čimbenike. Subjektivna vrijednost biologije se pokazala najsnažnijim prediktorom bihevioralne uključenosti. Dakle, učenici kojima je biologija subjektivno vrijedna, ulažu više truda na satu biologije, prate upute, sudjeluju u različitim aktivnostima i projektima vezanim uz biologiju, odnosno više su bihevioralno uključeni u nastavu. Takav rezultat je u skladu s prethodnim istraživanjima na predmetima STEM područja u kojima je subjektivna vrijednost pozitivan prediktor bihevioralne uključenosti (Boljkovac, 2018; Rovan i sur., 2017; Bektić Mihaljević, 2016). Iako je prema tim istim istraživanjima samoefikasnost značajan pozitivan prediktor te prema Bektić Mihaljević (2016), najsnažniji prediktor bihevioralne uključenosti u nastavi biologije, u ovom istraživanju to nije potvrđeno. Razlog tome mogu biti različita prošla iskustva učenika, različiti pristup nastavnika prema samom predmetu biologije te povratne informacije koje su im davali nakon što su obavili neki zadatak bezuspješno što je utjecalo na razinu samoefikasnosti , a samim time i na bihevioralno uključivanje.

U analizi kognitivne uključenosti kao kriterija, objašnjen je najveći dio varijance, 40.9%. Varijabla spola pokazala se značajnom u prva dva koraka hijerarhijske regresijske analize. Prema tome se može zaključiti kako su učenice više kognitivno uključene od učenika, odnosno psihološki ulažu više truda u razumijevanje složenih ideja na nastavi biologije i na primjenu strategija učenja. To je u skladu s rezultatima istraživanja Lama i suradnika (2016) te Reyesa i suradnika (2012), koji navode da djevojke prilikom učenja više provjeravaju razumiju

li naučeno, postavljaju si različita pitanja i pokušavaju si gradivo objasniti svojim riječima. Kada se u drugom koraku kao prediktor dodao prosjek ocjena na kraju prošle školske godine, on se pokazao značajnim pozitivnim prediktorom što znači da su oni učenici koji imaju viši akademski uspjeh i bolje ocjene, više kognitivno uključeni što je u skladu s rezultatima istraživanja Reyesa i suradnika (2012). O takvom odnosu akademskog uspjeha i kognitivne uključenosti, proučavalo se u istraživanju Chasea i suradnika (2014), koji navode da oni učenici koji uspješno napreduju u svom školovanju, više se kognitivno uključuju u nastavu jer su motivirani vlastitim uspjesima. Budući da žele napredovati još i više, odnosno postići što bolje ocjene, sudjelovanje u nastavi im svakako pomaže i olakšava ostvarivanje tog cilja. Rezultati dobiveni ovim istraživanjem djelomično su potvrdili početnu hipotezu o tome da će motivacijska uvjerenja (samoefikasnost i subjektivna vrijednost) pozitivno predviđati kognitivnu uključenost budući da se samoefikasnost nije pokazala značajnim samostalnim prediktorom. Subjektivna vrijednost biologije se pokazala najsnažnijim prediktorom kao i kod bihevioralne uključenosti prema čemu se može zaključiti kako oni učenici kojima je biologija subjektivno vrijedna i smatraju ju važnom za svoju budućnost (primjerice upis na željeni fakultet), ulažu više truda i energije u savladavanje složenih ideja i zadataka u nastavi biologije, odnosno više su kognitivno uključeni. Dobiveni rezultati su u skladu s rezultatima prethodnih istraživanja na predmetima STEM područja, u kojima je subjektivna vrijednost značajan pozitivan prediktor kognitivne uključenosti u nastavu kemije (Rovan i sur., 2017) te najsnažniji samostalni prediktor kognitivne uključenosti u nastavu biologije (Bektić Mihaljević, 2016).

Pri analizi strategija ciklusa (meta)kognitivne kontrole učenja kao kriterija objašnjeno je 26% varijance. Spol se kroz sva tri koraka pokazao kao značajan samostalan prediktor prema čemu se može zaključiti kako učenice u odnosu na učenike više koriste strategije ciklusa (meta)kognitivne kontrole učenja prilikom savladavanja gradiva iz biologije. Rezultati ovog istraživanja su u skladu s istraživanjem Gucek i Labak (2017), u kojem se pokazalo da učenice u odnosu na učenike češće postavljaju pitanja, ponavljaju gradiva i provjeravaju znanje u biologiji. U drugom koraku je dodan prosjek ocjena na kraju prošle školske godine kao prediktor koji je bio značajan i pozitivan što znači da oni učenici koji su imali viši prosjek, odnosno postigli viši akademski uspjeh, češće koriste strategije ciklusa (meta)kognitivne kontrole učenja i obrnuto. Istraživanje Vrdoljak i Vlahović-Štetić (2018) također je ispitivalo odnos akademskog uspjeha i strategija učenja i iako je provedeno na području predmeta fizike, rezultati su u skladu s rezultatima ovog istraživanja i govore o pozitivnoj povezanosti prosjeka ocjena i korištenja strategija ciklusa (meta)kognitivne kontrole učenja. Učenici koji postižu

odličan uspjeh češće ulažu više kognitivnog napora prilikom učenja i manje površno pristupaju učenju, odnosno više koriste strategije ciklusa (meta)kognitivne kontrole učenja (Matić i Marušić, 2016). Rezultati su samo djelomično potvrdili početnu hipotezu o tome da će motivacijska uvjerenja pozitivno predviđati strategije ciklusa (meta)kognitivne kontrole učenja, budući da samoefikasnost nije pokazana značajnim samostalnim prediktorom. Subjektivna vrijednost biologije je pokazana najsnažnijim prediktorom što znači da učenici kojima je biologija subjektivno vrijedna, češće koriste strategije ciklusa (meta)kognitivne kontrole učenja u odnosu na učenike kojima je neki drugi predmet, primjerice hrvatski jezik, subjektivno vrijedan.

U analizi strategija dubokog kognitivnog procesiranja kao kriterijskom varijablom objašnjeno je ukupno 22.4% varijance. U sva tri koraka spol se pokazao kao značajan samostalan prediktor iz čega se može zaključiti kako učenice više u odnosu na učenike koriste strategije dubokog kognitivnog procesiranja prilikom savladavanja gradiva iz biologije. U trećem koraku prosjek ocjena se pokazao značajnim, ali negativnim prediktorom što nije bilo za očekivati, zato što je korelacija prosjeka ocjena i strategija dubokog kognitivnog procesiranja, iako neznačajna, pozitivna. Takav rezultat može upućivati na to da je prosjek ocjena djelovao kao supresor varijabla. Prema rezultatima istraživanja Vrdoljak i Vlahović-Štetić (2018), ocjene, odnosno akademski uspjeh nije bio povezan sa strategijama dubokog kognitivnog procesiranja, dok je u ovom istraživanju prosjek ocjena na kraju prošle školske značajan i negativan prediktor što znači da su oni učenici koji su imali bolji prosjek, manje koristili strategije dubokog kognitivnog procesiranja i obrnuto. Ovakav rezultat upućuje na to da učenici žele imati što bolji prosjek, ali bez prevelikog dubinskog razumijevanja samog gradiva već nauče samo ono što im je potrebno kako bi dobili što višu ocjenu. Razlog tome može biti da neke teme na satu biologije nisu niti detaljno obrađivane te učenici ne pokazuju veliko zanimanje da si prodube gradivo već samo nauče površinski ono što je nastavnik prezentirao (Vrdoljak i Vlahović Štetić, 2018). Osim toga, svaki nastavnik ima slobodu da prema vlastitom interesu odabere koje će nastavne jedinice obraditi dublje, a koje ne. Prema tome može i odrediti način na koji će ispitivati znanje svojih učenika. Moguće je da nastavnici gimnazija koje su sudjelovale u ovom istraživanju koriste način ispitivanja znanje u kojem češće koriste zadatke koji ne potiču dubinsko razumijevanje nego doslovno učenje te su učenici manje skloni uporabi strategija dubokog kognitivnog procesiranja jer im i površinsko znanje o nekom gradivu dovoljno da uspješno riješe takvu vrstu zadataka te postignu odličan uspjeh.

Kao i kod strategija ciklusa (meta)kognitivne kontrole učenja, rezultati su samo djelomično potvrdili početnu hipotezu jer ni u ovoj analizi samoefikasnost nije pokazana značajnim samostalnim prediktorom. Subjektivna vrijednost biologije je ponovno pokazana najsnažnijim prediktorom.

Pri analizi strategija površinskog kognitivnog procesiranja kao kriterija, objašnjeno je 25.9% varijance. Za razliku od druge dvije vrste strategija učenja u kojima je spol bio značajan samostalan prediktor u sva tri koraka hijerarhijske regresijske analize, u ovoj se analizi nije pokazao značajnim ni u jednom od sva tri koraka. To je bilo za očekivati prema rezultatima korelacija, ali i rezultatima prethodnih istraživanja u kojima se spol nije pokazao značajnim prediktorom, odnosno nije bilo razlike između djevojaka i mladića u korištenju strategija površinskog kognitivnog procesiranja. Prosjek ocjena je značajan negativan samostalan prediktor i u drugom i u trećem koraku, a općenito i najsnažniji prediktor. Prema tome, oni učenici koji su imali bolji prosjek ocjena na kraju prošle školske godine, manje koriste strategije površinskog kognitivnog procesiranja i obrnuto. Takvi rezultati su u skladu s rezultatima prethodnih istraživanja prema kojima učenici s dobrim uspjehom (prosjek ocjena između 2.5 i 3.4) više koriste strategije površinskog kognitivnog procesiranja u odnosu na učenike koji postižu vrlo dobar (prosjek ocjena između 3.5 i 4.4) i odličan uspjeh (prosjek ocjena veći od 4.5) (Matić i Marušić, 2016; Nikčević-Milković, Jerković i Biljan, 2014; Rijavec, i sur., 1999). Istraživanje čiji je interes bio fizika kao specifičan predmet STEM područja, pokazalo je da su oni učenici koji su napamet učili pojmove i koncepte iz fizike te bez razumijevanja, postizali niži uspjeh u fizici (Vrdoljak i Vlahović-Štetić, 2018). Hipoteza koja je postavljena je potvrđena budući da se očekivalo da će samoefikasnost i subjektivna vrijednost biologije negativno predviđati korištenje strategija površinskog kognitivnog procesiranja, što je i dobiveno provedenom analizom. Za očekivati je da ukoliko učenici procjenjuju svoje sposobnosti izvršavanja obaveza na nastavi biologije kao više te gradivo biologije smatraju važnim za svoju budućnost, manje koriste strategije *nižeg reda,* odnosno površinskog kognitivnog procesiranja već će više truda i napora uložiti za savladavanje gradiva.

Sveukupno gledajući, provedeno istraživanje je pokazalo da od uključenih prediktora, subjektivna vrijednost biologije najbolje pridonosi objašnjenju varijance kognitivne i bihevioralne uključenosti te strategija dubokog kognitivnog procesiranja. Prema tome, učenici kojima je biologija subjektivno vrijedna i važna za budućnost, više će se bihevioralno i kognitivno uključivati u nastavu te koristiti strategija dubokog kognitivnog procesiranja. Za preostale strategije učenja, subjektivna vrijednost biologije je značajan prediktor, ali ne i

najsnažniji jer je to za strategije (meta)kognitivne kontrole učenja spol, dok je za strategije površinskog kognitivnog procesiranja to prosjek ocjena na kraju prošle školske godine. Dobiveni rezultati mogu se objasniti time da oni učenici koji određene specifične predmete smatraju važnijima za budućnost, ali i svakodnevicu, ulažu mnogo više truda i napora u rješavanju određenih zadataka i savladavanju gradiva (Marušić, 2006). Prema tome, ako je učenicima biologija važna za daljnji upis fakulteta medicine ili biologije, a žele i određeno gradivo upotrebljavati u svakodnevnom životu, više će sudjelovati na projektima vezanim uz biologiju, pohađati dodatnu nastavu, sudjelovati na natjecanjima te dubinski savladavati gradivo.

Osim što se strategije površinskog kognitivnog procesiranja razlikuju od ostalih kriterijskih varijabli po najsnažnijem prediktoru, razlika je i u tome što je samoefikasnost za te strategije značajan negativan prediktor, dok za ostale nije značajan. Značajnost tog prediktora može se objasniti time da one osobe koje imaju niži stupanj samoefikasnosti- biraju lakše zadatke u testu koje će riješiti, ulažu manje truda u savladavanje gradiva biologije i u tome im pomažu upravo strategije površinskog kognitivnog procesiranja jer one podrazumijevaju učenje napamet, bez puno napora i promišljanja (Lončarić, 2014).

Hipoteze nisu u potpunosti potvrđene kada je u pitanju samoefikasnost kao značajan prediktor, osim za strategije površinskog kognitivnog procesiranja iako se to prema početnim bivarijantnim korelacijama očekivalo. Dobiveni rezultat vjerojatno je posljedica međusobne umjerene korelacije između samoefikasnosti i subjektivne vrijednosti koje su skupno uvedene u treći korak hijerarhijske regresijske analize. Uzevši u obzir to te činjenicu da subjektivna vrijednost biologije snažnije korelira s kriterijskim varijablama od samoefikasnosti, dobiveni rezultati se mogu jasnije tumačiti.

Uvjerenja o samoefikasnosti formiraju se na osnovi prijašnjih iskustava učenika, opažanju uspješnosti drugih, vjerovanjima koje bliske osobe daju učenicima o njihovim sposobnostima te na temelju fizioloških i emocionalnih stanja (Reić Ercegovac i Koludrović, 2010). Prema tome, moguće je da su učenici ovog istraživanja doživjeli neuspjeh u savladavanju određenog zadatka na satu biologije (pokusi, uzgajanje biljaka) te je sudjelovanje u nekim aktivnostima zahtijevalo preveliku pomoć drugih učenika. Također je moguće da je netko od drugih učenika, koji se percipira sličnim, doživio neuspjeh u savladavanju zadatka koji se nije činio zahtjevnim. Nadalje, vrlo su važne povratne informacije koje se dobivaju od drugih osoba te je moguće da to profesori i roditelji nisu formulirali na učinkovit način. Posljednje, moguće je da su učenici osjećali preveliki strah prema nastavnicima, primjerice da

se javljaju na satu da bi odgovorili na postavljeno pitanje jer su nastavnici skloni lošem reagiranju na pogrešan odgovor ili su strah prije testa pripisivali manjku svojih sposobnosti. Za optimalno funkcioniranje je važno da pobuđenost nije ni previsoka ni preniska, stoga je važno da učenici budu svjesni da je određena razina straha i napetosti prije testa nešto što zapravo pomaže u izvedbi (Bandura, 1986, prema Sorić, 2014). Prema Banduri (1991), uvjerenja o samoefikasnosti koje učenici imaju i stvaraju prema svemu prethodno navedenom, utječu na odabir ciljeva usmjerene aktivnosti te prema tome ako učenici ovog istraživanja percipiraju da neće uspjeti u izvršavanju nekog zadatka na nastavi biologije, neće ni koristiti strategije *višeg reda* niti se uključivati u nastavu.

Doprinosi istraživanja

Doprinos ovog istraživanja jest svakako odabrani specifični predmet STEM područja-biologija, budući da je do sada češće istraživan odnos motivacijskih uvjerenja s uključenošću učenika u području matematike, kemije i fizike. Motivacijske varijable (samoefikasnost i vrijednosti) su se do sada većinom pojavljivale u istraživanjima vezanim uz akademski uspjeh, no važno je naglasiti kako je istraživanje njihovog odnosa s uključenošću vrijedno. Uključenost može unaprijediti akademske ishode, smanjiti nepoželjno akademsko ponašanja i nezainteresiranost učenika (Christenson i sur., 2012) te se istraživanjem koje sve individualne osobine učenika objašnjavaju razlike u učenikovoj uključenosti na nastavi biologije može pomoći profesorima u srednjim školama da imaju jasniji uvid u to zašto su neki učenici više, a neki manje uključeni u nastavu na njihovom satu.

Konstrukt uključenosti je promjenjiv i nastavnici mogu svojim trudom i angažmanom povećati uključenost učenika na svojoj nastavi i tako ju unaprijediti. Komponenta bihevioralne uključenosti podrazumijeva sudjelovanje učenika u raspravama, projektima i različitim aktivnostima, stoga se uključenost učenika u nastavu biologije može potaknuti primjerice debatama, projektima, sudjelovanjem u pokusima i drugim grupnim radovima koji će biti učenicima zanimljiviji od frontalnog rada.

Motivacijske varijable samoefikasnosti i vrijednosti također se mogu mijenjati i nastavnici ih svojim postupcima mogu povećati, odnosno utjecati na njihov rast. U istraživanju Ainscougha i suradnika (2016), provjeravala se razina samoefikasnosti te mogući utjecaji na nju na početku i na kraju prve godine biologije na fakultetu i prema rezultatima, primarni utjecaj na povećanje samoefikasnosti su trenutna iskustva studenata s biologijom, ono što im nastavnici

pružaju te povratne informacije koje im daju vezano uz sve aktivnosti u kojima sudjeluju. Osim toga, Siegle i McCoach (2007) su istraživali može li se samoefikasnost u matematici povećati ako nastavnici promjene način rada i koriste drugačije nastavne metode te su rezultati pokazali da je za povećanje samoefikasnosti najvažnije naglašavanje prošlih uspjeha i iskustava, povratne informacije i modeli nastavnika s kojima se učenici susreću. Uzevši u obzir prethodno spomenuto, nastavnici biologije mogu povećati razine samoefikasnosti i vrijednosti na način da potiču učenike da sudjeluju u aktivnostima na nastavi biologije, da ne odustaju prebrzo te da naglašavaju kako je biologija vrlo važna za svakodnevni život, kako će gradivo biologije moći i kasnije primjenjivati bez obzira na odabir posla ili fakulteta. Takav način održavanja nastave biologije i rada profesora uz česte i konkretne povratne informacije, učenicima će omogućiti veću aktivnost u izvršavanju školskih obaveza i više će se posvećivati obrazovnim ciljevima, odnosno bit će više uključeni na nastavi.

Još jedan od doprinosa ovog istraživanja je proučavani odnos motivacijskih uvjerenja i strategija učenja koji je do sada nedovoljno istražen u STEM području, posebice u specifičnom predmetu biologije. Strategije učenja je važno istraživati budući da su one učenikove akcije koje poduzima prilikom učenja kako bi što brže, lakše i učinkovitije savladao neko gradivo, a zanimljivo je proučavati koje individualne osobe mogu utjecati na njihovo korištenje. Prema Vizek Vidović i suradnicima (2014), vrlo je važno poticati učenike da upotrebljavaju strategije ciklusa (meta)kognitivne kontrole učenja i strategije dubokog kognitivnog procesiranja jer će na taj način učiti s razumijevanjem i primijeniti znanje u novim situacijama, kako obrazovnim, tako i svakodnevnim osobnim .

Doprinos ovog istraživanja je i taj da se rezultati mogu upotrijebiti u praktične svrhe jer se bavilo time koja sve motivacijska uvjerenja i individualne osobine mogu odrediti korištenje određenih strategija učenja u savladavanju gradiva biologije. Kao što je već i spomenuto da su samoefikasnost i vrijednosti kao motivacijska uvjerenja promjenjivi, nastavnici poticanjem njihovog rasta mogu utjecati i na povećanje korištenja strategija učenja *višeg reda*, odnosno smanjivanje strategija učenja *nižeg reda*. Ovo istraživanje može potaknuti nastavnike da pomognu učenicima otkriti koje su to sve strategije učenja koji oni uopće mogu koristiti i što im koje od njih donose. Za to je vrlo važno stvoriti i dobro školsko ozračje u kojem će učenici moći uvježbavati određene strategije te ih i usavršavati.

Na temelju rezultata ovog istraživanja također se može potaknuti nastavnike da pobude interes učenika prema predmetima STEM područja i da se kasnije nastave baviti znanošću. Korištenjem znanja o tome kako povećati samoefikasnost učenika i vrijednosti kao neke od

motivacijskih uvjerenja, nastavnici mogu učenicima dokazati da se uključivanjem u različite aktivnosti može naučiti i dobiti mnogo te da se uz pravilno korištenje strategija učenja može savladati i gradivo za koje se to činilo nemogućim.

Posljednji doprinos ovog istraživanja jest sudjelovanje učenika iz područja Republike Hrvatske koje nije u dovoljnoj mjeri obuhvaćeno u prethodnim istraživanjima. Dosadašnji uzorak činili su ponajviše srednjoškolci zagrebačkih škola, dok su o ovome odabrani srednjoškolci s područja Krapinsko-zagorske županije koji svakako imaju drugačije prilike za susret s predmetima iz STEM područja budući da su iz manjih mjesta. Rezultati ovog istraživanja mogu biti prezentirani ravnateljima škola i predmetnim nastavnicima kako bi ih se potaknulo da učenicima što zanimljivije prezentiraju predmete STEM područja i osvijeste potrebu za budućim bavljenjem nekim od ponuđenih područja i tako sa svojim znanjem i sposobnostima pomognu rastu i razvoju manjih mjesta na području Krapinsko-zagorske županije.

Ograničenja istraživanja i prijedlozi za buduća istraživanja

Prvo ograničenje ovog istraživanja jest njegov korelacijski nacrt te prikupljanje podataka u samo jednoj vremenskoj točki što ne omogućava zaključivanje o uzročno-posljedičnim vezama. U budućim istraživanjima bi stoga moglo biti provedeno longitudinalno istraživanje koje bi pratilo promjene u korištenim varijablama kroz osnovnu i srednju školu. Na taj način moglo bi se provjeriti i imaju li intervencije nastavnika utjecaj na razvoj motivacijskih uvjerenja, a samim time i na uključenost i korištenje strategija učenja.

Nadalje, još jedno od ograničenja jest i način odabira uzorka koji je prigodan. Istraživanje je provedeno u samo tri opće gimnazije s područja Krapinsko-zagorske županije što onemogućava generalizaciju podataka na ostale opće gimnazije s tog područja ili šire po cijeloj državi. Budući da se radilo samo o jednom gimnazijskom smjeru, može se zaključiti kako je njihovo razmišljanje o znanosti sličnije nego što bi to bilo, primjerice, kod učenika prirodoslovno-matematičkih gimnazija. Kada bi se ispitali učenici drugih škola ili drugih gimnazijskih smjerova, vjerojatno bi se dobili drugačiji rezultati vezani uz uključenost u učenje i nastavu te korištenje strategija učenja. Razlog tome mogu biti mnogi osobni čimbenici učenika, ali i njihov različiti doticaj s okolinskim čimbenicima, radi čega bi valjalo uključiti raznolikiji uzorak. Osim toga, nedostatak ovog istraživanja je i nejednak omjer učenica i učenika budući da je sudjelovalo dvostruko više učenica stoga bi trebalo pokušati uključiti i što

više učenika u sudjelovanje. Bilo bi također zanimljivo napraviti usporedbu rezultata ovog istraživanja s istraživanjem koje bi se provelo u općim gimnazija u nekom većem gradu, primjerice Zagrebu ili Varaždinu kako bi se provjerile kakve su zaista razlike u uključenosti i korištenju strategija učenja u specifičnom predmetu STEM područja ovisno o mjestu stanovanja.

Treće ograničenje ovog istraživanja odnosi se na metodu prikupljanja podataka, tehniku samoprocjene koja je podložna socijalno poželjnom odgovaranju što onda utječe na valjanost rezultata i zahtijeva oprez pri interpretaciji. Iako se tijekom davanja upute za ispunjavanje upitnika više puta naglasila anonimnost i povjerljivost podataka, učenici su upitnik ispunjavali grupno i ponekad u prisutnosti predmetnog nastavnika pa se ne može u potpunosti tvrditi kako su na sva pitanja odgovorili iskreno. Iako se motivacijska uvjerenja ne mogu izmjeriti drugačije nego tehnikom samoprocjene, uključenost i korištenje strategija učenja moglo bi se izmjeriti promatranjem u prirodnim uvjetima, na samom satu nekog predmeta ili koristiti procjene nastavnika i roditelja. Nastavnici bi mogli dobro procijeniti uključenost učenika na nastavu jer najbolje znaju koliko su učenici kognitivno i bihevioralno uključeni na njihovom satu, dok bi roditelji bolje procijenili korištenje strategija učenja njihovog djeteta jer znaju koji način učenja im omogućava što brže i efikasnije savladavanje gradiva.

Ono što je također primijećeno tijekom prikupljanja podataka jest razlika u motivaciji učenika za ispunjavanje upitnika koja je bila podložna okolinskim utjecajima. Na to koliko će odgovori učenika biti iskreni, mogli su utjecati uvjeti u učionici, to kako su se taj dan osjećali i brojne druge individualne osobine. Osim toga u jednom razredom odjeljenju su učenici na sljedećem nastavnom satu imali test, pa su svi htjeli što brže ispuniti upitnik kako bi što više vremena imali za ponavljanje gradiva. Iako je bilo teško uskladiti vrijeme dolaska u škole radi provođenja testiranja s ravnateljima, stručnim suradnicima i nastavnicima, ubuduće bi se trebali izbjegavati satovi neposredno pred test.

Korištenim skupom prediktorskih varijabli nije objašnjen visok postotak varijance kriterijskih varijabli, osim za kognitivnu uključenost što se također može poboljšati. Stoga bi se u budućim istraživanja mogle dodati i druge prediktorske varijable kako bi se pokušao objasniti što veći postotak varijance kriterija. Prediktorski skup varijabli mogao bi uključivati osobine ličnosti učenika, nastavnikove kompetencije te roditeljsku kontrolu i druge karakteristike roditelja koje prema Šimić Šašić, Klarin i Proroković (2011) utječu na odnos roditelja i djeteta, a samim time i na motivaciju i strategije učenja samog učenika i njegov školski uspjeh.

Budući da je iznenađujući rezultat da je prosjek ocjena na kraju prošle školske godine negativan prediktor strategija dubinskog kognitivnog procesiranja, u budućim istraživanjima trebalo bi se kao prediktorske varijable dodati i ciljeve postignuća kako bi se provjerilo imaju li oni utjecaj na korištenje određenih vrsta strategija učenja. Vezano uz to, mogla bi se dodati i prediktorska varijabla koja je vezana uz vrstu zadataka kojim se ispituje znanje biologije što također može biti povezano s korištenjem određenih strategija učenja.

Osim toga, zanimljivo bi bilo dodati prediktorske varijable koje bi obuhvaćale sustave prema *Ekološkoj teoriji* Uriea Bronfenbrennera (1979) što je dijelom obuhvaćeno u istraživanju Lama i suradnika (2016). Oni su proučavali odnos uključenosti s podrškom koja se dobiva od nastavnika, vršnjaka i roditelja što je dio mikrosustava te kulturalne vrijednosti i socioekonomske mogućnosti kao dio makrosustava. U budućnosti bi se na sličnom uzorku kakav je u ovom istraživanju mogao provjeriti odnos uključenosti i strategija učenja s varijablama iz pojedinog sustava. Tako bi se kao dio mikrosustava primjerice mogao odabrati utjecaj roditelja, nastavnika i vršnjaka, zatim suradnja roditelja i škole kao dio mezosustava, postojanje dopunske i dodatne nastave kao dio egzosustava, financiranje nastavnog materijala ili stipendije kao dio makrosustava i posljednje bi bilo zanimljivo provjeriti ima li modularna nastava kao dio eksperimentalnog programa *Škola za život* utjecaj na količinu uključenosti ili korištenja različitih strategija učenja.

Zaključak

Cilj ovog istraživanja bio je ispitati odnos motivacijskih uvjerenja (samoefikasnost i subjektivna vrijednost) sa strategijama učenja i uključenošću učenika u učenje i nastavu biologije. Kako bi se odgovorilo na istraživačke probleme, provedene su hijerarhijske regresijske analize za svaku od pet kriterijskih varijabli. Dobiveni rezultati su djelomično potvrdili postavljene hipoteze.

Odabrane prediktorske varijable objasnile su dio varijance kriterijskih varijabli s tim da je najveći postotak varijance objašnjen za kognitivnu uključenost, a najmanji za strategije dubokog kognitivnog procesiranja. Subjektivna vrijednost se pokazala najboljim prediktorom bihevioralne i kognitivne uključenosti te strategija dubokog kognitivnog procesiranja. Spol je najsnažniji prediktor strategija (meta)kognitivne kontrole učenja, dok je prosjek ocjena na kraju prošle školske godine najznačajniji prediktor strategija površinskog kognitivnog procesiranja. Sukladno prethodnim istraživanjima, spol je bio značajan samostalan prediktor za bihevioralnu uključenost, strategije ciklusa (meta)kognitivne kontrole učenja i dubokog kognitivnog

procesiranja. Prema nalazima prethodnih istraživanja, očekivalo se kako će samoefikasnost biti značajan samostalan prediktor svih kriterijskih varijabli, no ona jedino značajno doprinose objašnjavanju varijance strategija površinskog kognitivnog procesiranja.

Dobiveni rezultati mogu se koristiti u praktične svrhe na način da potaknu nastavnike da potiču rast i razvoj samoefikasnosti i vrijednosti i na taj način povećaju razinu uključenosti u nastavu biologije. Osim toga, nastavnici mogu promijeniti svoj način rada tako da stvaraju bolje školsko ozračje u kojem će učenici otkrivati moguće strategije učenja biologije, uvježbavati njihovo korištenje i na taj način si pomoći u što lakšem savladavanju gradiva. U budućim istraživanjima potrebno je detaljnije provjeriti odnose uključenosti u nastavu, korištenje strategija učenja s motivacijskim uvjerenjima, ali i drugim prediktorskim varijablama.

Literatura

Ainscough, L., Foulis, E., Colthorpe, K., Zimbardi, K., Robertson-Dean, M., Chunduri, P. i Lluka, L. (2016). Changes in biology self-efficacy during a first-year university course. *CBE—Life Sciences Education*, *15*(2), 1-12.

Appleton, J. J., Christenson, S. L. i Furlong, M. J. (2008). Student engagement with school: Critical conceptual and methodological issues of the construct. *Psychology in the Schools*, *45*(5), 369-386.

Astin, A.W. (1999). Student involvement: A developmental theory for higher education**,** *Journal of college student development*, *40*, 518-529.

Bandura, A. (1991). Self-regulation of motivation through anticipatory and self-reactive mechanisms. *Perspectives on motivation: Nebraska symposium on motivation*, *38*(1), 69-164.

Bandura, A. (1997), *Self-efficacy: The exercise of control*. New York: Freeman.

Bektić Mihaljević, M. (2016). *Povezanost epistemičkih uvjerenja i motivacijskih varijabli s uključenosti učenika u nastavu biologije*. Neobjavljeni diplomski rad. Zagreb: Odsjek za psihologiju Filozofskog fakulteta u Zagrebu.

Boljkovac, E. (2018). *Povezanost motivacijskih uvjerenja i kvalitete školskog života s uključenosti učenika u učenje fizike.* Neobjavljeni diplomski rad. Zagreb: Odsjek za psihologiju Filozofskog fakulteta u Zagrebu.

Brankica, Z. (2014). Utjecaj projektne nastave na promjenu stava kod učenika prema nastavnim sadržajima iz biologije. *Educatio biologiae: časopis edukacije biologije*, *1*(1), 18-26.

Britner, S. L., i Pajares, F. (2006). Sources of science self-efficacy beliefs of middle school students. *Journal of Research in Science Teaching*, *43*(5), 485-499.

Brković, I., Keresteš, G. i Kuterovac-Jagodić, G. (2012). Usporedba rezultata transverzalnoga i longitudinalnoga pristupa procjeni razvoja samoregulacije u ranoj adolescenciji. *Psihologijske teme*, *21*(2), 273-297.

Bronfenbrenner, U. (1979). *The ecology of human development*. Cambridge: Harvard university press.

Chase, P. A., Hilliard, L. J., Geldhof, G. J., Warren, D. J. i Lerner, R. M. (2014). Academic achievement in the high school years: The changing role of school engagement. *Journal of Youth and Adolescence*, *43*(6), 884-896.

Christenson, S. L., Reschly, A. L. i Wylie, C. (2012). *Handbook of research on student engagement*. Berlin: Springer Science i Business Media.

Corlu, M. S., Capraro, R. M. i Capraro, M. M. (2014). Introducing STEM education: Implications for educating our teachers in the age of innovation. *Education and Science*, *39*(171), 74-85.

Domazet, M. (2009). Društvena očekivanja i prirodo-znanstveno kompetentni učenici. *Sociologija i prostor: časopis za istraživanje prostornoga i sociokulturnog razvoja*, *47*(2 (184)), 165-185.

Đukić, S., Radusinović, D. i Vukčević, M. (2013). Koncept akademske samoefikasnosti i veza sa školskim postignućem. *Godisnjak za psihologiju*, *9*(11), 9-9.

Eccles, J. S. (2005). *Subjective task values and the Eccles et al. model of achievement related choices. U: A. J. Handbook of competence and motivation.* New York: Guilford.

Eccles, J.S. i Wigfield, A. (2002). Motivational beliefs, values, and goals. *Annual Review of Psychology, 53*, 109-132.

Fredricks, J.A., Blumenfeld, P.C. i Paris, A.H. (2004). School engagement: Potential of the concept, state of the evidence. *Review of Educational Research*, *74*, 59-109.

Garcia, T. i Pintrich, P. R. (1994). Regulating motivation and cognition in the classroom: The role of self-schemas and self-regulatory strategies. *Self-regulation of learning and performance: Issues and educational applications*, *127153*, 433-452.

Gucek, M. i Labak, I. (2017). Navike učenja i uspješnost učenika srednje škole u nastavi biologije. *Educatio biologiae: časopis edukacije biologije*, *3*(1), 63-72.

Jakšić, M. i Vizek Vidović, V. (2008). Ciljevi postignuća, percepcija kompetentnosti, spol i strategije učenja u općem akademskom kontekstu. *Suvremena psihologija, 11*(1), 7-24.

Jandrić, D., Boras, K. i Šimić, Z. (2018). Rodne i dobne razlike u motivaciji i samoregulaciji učenja. *Psihologijske teme, 27*(2), 177-193.

Jugović, I., Baranović, B. i Marušić, I. (2012). Uloga rodnih stereotipa i motivacije u objašnjenju matematičkog uspjeha i straha od matematike. *Suvremena psihologija*, *15*(1), 65-78.

Kong, Q., Wong, N. i Lam, C. (2003). Student engagement in mathematics: Development and validation of construct. *Mathematics Education Research Journal*, *15*(1), 4–21.

Lam, S. F., Jimerson, S., Shin, H., Cefai, C., Veiga, F. H., Hatzichristou, C., Polychroni, F., Kikas, E., Wong, P.H.B., Stanculescu, E., Basnett, J., Duck, R., Farrell, P, Liu, Y., Negovan, V., Nelson, B., Yang, H. i Zollneritsch, J. (2016). Cultural universality and specificity of student engagement in school: The results of an international study from 12 countries. *British Journal of Educational Psychology*, *86*(1), 137-153.

Lončarić, D. (2014). *Motivacija i strategije samoregulacije učenja: teorija, mjerenje i primjena.* Rijeka: Učiteljski fakultet u Rijeci.

Marušić, I. (2006). Motivacija i školski predmeti: spolne razlike u kontekstu teorije vrijednosti i očekivanja. *Nacionalni kurikulum za obvezno obrazovanje u Hrvatskoj-različite perspektive*, *18* (1), 219-257.

Matić, J. i Marušić, I. (2016). Razlike u samopoimanju i korištenju strategija učenja među učenicima različitog školskog uspjeha. *Napredak: časopis za pedagogijsku teoriju i praksu, 157*(3), 283-299.

Matijević, M. (2017). *Nastava i škola za net-generacije*. Zagreb: Učiteljski fakultet Sveučilišta u Zagrebu.

Nikčević-Milković, A., Jerković, A. i Biljan, E. (2014). Povezanost komponenti samoregulacije učenja sa školskim uspjehom i zadovoljstvom školom kod učenika osnovnoškolske dobi. *Napredak: časopis za pedagogijsku teoriju i praksu, 154*(4), 375-398.

Nikčević-Milković, A., Jerković, A., & Biljan, E. (2014). Povezanost komponenti samoregulacije učenja sa školskim uspjehom i zadovoljstvom školom kod učenika osnovnoškolske dobi. *Napredak: časopis za pedagogijsku teoriju i praksu*, *154*(4), 375-398.

Pajares, F. (2002). Gender and perceived self-efficacy in self-regulated learning. *Theory into practice, 41*(2), 116-125.

Pavlin-Bernardić, N., Putarek, V., Rovan, D., Petričević, E. i Vlahović-Štetić, V. (2017). Students' engagement in learning physics: A subject-specific approach. In *20th Psychology Days in Zadar: Book of Selected Proceedings*. University of Zadar.

Pintrich, P. R. i De Groot, E. V. (1990). Motivational and self-regulated learning components of classroom academic performance. *Journal of Educational Psychology, 82*(1), 33-40.

Putarek, V., Rovan, D. i Vlahović-Štetić, V. (2016). Odnos uključenosti u učenje fizike s ciljevima postignuća, subjektivnom vrijednosti i zavisnim samopoštovanjem. *Društvena istraživanja: časopis za opća društvena pitanja*, *25*(1), 107-129.

Ratkajec Gašević, G., Dodig Hundrić, D. i Mihić, J. (2016). Spremnost na promjenu ponašanja–od individualne prema obiteljskoj paradigmi. *Kriminologija & socijalna integracija: časopis za kriminologiju, penologiju i poremećaje u ponašanju*, *24*(1), 50-83.

Reeve, J. (2012). *A self-determination theory perspective on student engagement. In Handbook of research on student engagement* . Boston: Springer.

Reić Ercegovac, I. i Koludrović, M. (2010). Akademska samoefikasnost i školski uspjeh adolescenata. *Pedagogijska istraživanja*, *7*(1), 111-126.

Reyes, M. R., Brackett, M. A., Rivers, S. E., White, M. i Salovey, P. (2012). Classroom emotional climate, student engagement, and academic achievement. *Journal of educational psychology*, *104*(3), 700.

Riechert, S. E. i Post, B. K. (2010). From skeletons to bridges & other STEM enrichment exercises for high school biology. *The american biology Teacher*, *72*(1), 20-22.

Rijavec, M., Raboteg-Šarić, Z. i Franc, R. (1999). Komponente samoreguliranog učenja i školski uspjeh. *Društvena istraživanja: časopis za opća društvena pitanja*, *8*(4 (42)), 529-541.

Rovan, D. (2011). *Odrednice odabira ciljeva pri učenju matematike u visokom obrazovanju*. Neobjavljeni doktorski rad. Zagreb: Odsjek za psihologiju Filozofskog fakulteta u Zagrebu.

Rovan, D. i Jelić, A. B. (2010). Motivacijska uvjerenja u učenju materinskoga jezika i stranih jezika. *Društvena istraživanja: časopis za opća društvena pitanja*, *19*(4-5 (108-109)), 873-894.

Rovan, D., Pavlin-Bernardić, N. i Vlahović-Štetić, V. (2013). Struktura motivacijskih uvjerenja u matematici i njihova povezanost s obrazovnim ishodima. *Društven istraživanja, 22*, 475-495.

Rovan, D., Šimić, K. i Pavlin-Bernardić, N. (2017). Odnos motivacijskih i epistemičkih uvjerenja s uključenosti učenika u učenje kemije. *Psihologijske teme, 26*(3), 649-673.

Siegle, D. i McCoach, D. B. (2007). Increasing student mathematics self-efficacy through teacher training. *Journal of Advanced Academics*, *18*(2), 278-312.

Skinner, E. A., Kindermann, T. A., Connell, J. P. i Wellborn, J. G. (2009). Engagement and disaffection as organizational constructs in the dynamics of motivational development. *Handbook of motivation at school, 1,* 223-245.

Sorić, I. (2014). *Samoregulacija učenja*. Jastrebarsko: Naklada Slap.

Šimić Šašić, S., Klarin, M. i Proroković, A. (2011). Socioekonomske prilike obitelji i kvaliteta obiteljske interakcije kao prediktori školskog uspjeha srednjoškolaca u Hrvatskoj, Bosni i Hercegovini i Makedoniji. *Ljetopis socijalnog rada, 18*(1), 31-62.

Tenaw, Y. A. (2013). Relationship between self-efficacy, academic achievement and gender in analytical chemistry at Debre Markos College of teacher education. *African Journal of Chemical Education, 3*(1), 3-28.

Vizek Vidović, V., Rijavec, M., Vlahović-Štetić, V. i Miljković, D. (2014). *Psihologija obrazovanja*. Zagreb: IEP.

Vrdoljak, G. i Vlahović-Štetić, V. (2018). Odnos ciljeva postignuća, strategija učenja i ocjena u srednjoškolskoj nastavi fizike. *Psychological Topics, 27*(2), 141.

Vrkić, M. i Vlahović Štetić, V. (2013). Uvjerenja o strategijama učenja, korištenje strategija učenja i uspjeh u studiju. *Napredak: časopis za pedagogijsku teoriju i praksu, 154*(4), 511-526.

Wigfield, A. i Eccles, J. S. (2000). Expectancy–Value theory of achievement motivation. *Contemporary educational psychology, 25*, 68–81.

Witt-Rose, L.D. (2003). *Student self-efficacy in college science: An investigation of gender, age and academic achievement.* Unpublished research paper. Wisconsin: Graduate School, University of Wisconsin-Stout.

Yusuf, M. (2011). The impact of self-efficacy, achievement motivation, and self-regulated learning strategies on students' academic achievement. *Procedia-Social and Behavioral Sciences, 15,* 2623-2626.

Zimmerman, B. J. (1995). Self-regulation involves more than metacognition: *A social cognitive perspective. Educational Psychologist, 30,* 217-221.