



<https://doi.org/10.5559/di.27.4.01>

UČINCI STEM INTERVENCIJSKOGA PROGRAMA U OSNOVNIM ŠKOLAMA NA STAVOVE I INTERESE UČENIKA: PRIMJENA TEHNIKE UPARIVANJA PREMA SKLONOSTI

Toni BABAROVIĆ

Institut društvenih znanosti Ivo Pilar, Zagreb

Predrag PALE

Fakultet elektrotehnike i računarstva, Zagreb

Josip BURUŠIĆ

Institut društvenih znanosti Ivo Pilar, Zagreb

UDK: 373.3.048:001

Izvorni znanstveni rad

Primljeno: 19. 1. 2018.

Uz velik broj programa usmjerenih prema poboljšanju uspjeha učenika u STEM predmetima ili povećanju njihova interesa za STEM područje, jača i svijest o metodološkim izazovima u organizaciji, provedbi i evaluaciji STEM intervencija. U ovom je radu evaluirana učinkovitost jedne STEM intervencije kvaziekperimentalnim istraživanjem u kojem je sudjelovalo 1484 učenika, 4., 5. i 6. razreda osnovne škole. Mjere učinka tretmana bile su stavovi prema zaposlenima u STEM području te interesi za STEM zanimanja. Pri provjeri učinkovitosti intervencije primijenjena je tehnika uparivanja prema sklonosti (eng. *Propensity Score Matching*). Rezultati pokazuju da se STEM intervencijom mogu, u maloj mjeri, povećati pozitivni stavovi prema znanstvenicima te da dolazi do malih pozitivnih pomaka i u povećanju STEM interesa kod mlađih učenika. Istraživanjem se pokazalo da tehnika uparivanja prema sklonosti ima svoju primjenu u evaluacijskim istraživanjima intervencija u obrazovanju.

Ključne riječi: STEM, evaluacija intervencije, tehnika uparivanja prema sklonosti, stavovi prema znanstvenicima, profesionalni interesi



Toni Babarović, Institut društvenih znanosti Ivo Pilar,
Marulićev trg 19/1, p. p. 277, 10 001 Zagreb, Hrvatska.
E-mail: Toni.Babarovic@pilar.hr

UVOD

STEM intervencije i njihov učinak

U zadnjih dvadesetak godina u mnogim je europskim državama uočen pad broja studenata koji odabiru nastavak obrazovanja u STEM (znanost, tehnologija, inženjerstvo i matematika) području (European Commission, 2004; Osborne i Dillon, 2008). S tim u vezi, većina europskih država u zadnje vrijeme doživljava poteškoće u zapošljavanju STEM kvalificirane radne snage (Caprile, Palmén, Sanz i Dente, 2015). Kako bi proučili uzroke toga pada te potaknuli učenike na nastavak obrazovanja i karijere u STEM području, provedena su mnoga istraživanja koja su proučavala vezu između učeničke motivacije za STEM područje, njihovih obrazovnih ishoda u STEM predmetima te odabira STEM karijera. Isto tako, mnogi su istraživači provodili intervencije za poboljšanje motivacije učenika za STEM predmete i povećanje interesa za STEM područje. Međutim, do danas, ovo područje istraživanja nije temeljito preispitano, a najbolji recentni uvid u dosadašnje spoznaje o učinkovitosti STEM intervencija pružili su Rosenzweig i Wigfield (2016).

Na osnovi sistematičnoga pregleda literature autori su klasificirali intervencijske programe s obzirom na motivacijske konstrukte na koje su bili usmjereni. Prepoznali su pet osnovnih kategorija intervencija: intervencije usmjerene na: a) vjerovanja o vlastitim kompetencijama (npr. samoeфикаsnost, samopoimanje, samopouzdanje, očekivanje ishoda); b) vrijednosti, interese i intrinzičnu motivaciju; c) atribucije akademskog uspjeha ili neuspjeha; d) vjerovanje o vlastitim sposobnostima (ponajprije inteligenciji) i e) orijentaciju prema postignuću. Bez obzira na specifičan cilj samih intervencija, rezultati istraživanja pokazuju da intervencije imaju stanovit učinak na povećanje motivacije učenika i poboljšanje uspjeha u STEM predmetima. Međutim, utvrđeno je da veličina učinka intervencija u velikoj mjeri varira te da su učinci najčešće mali do umjereni.

Rosenzweig i Wigfield (2016) došli su do uvida kako je većina STEM intervencijskih programa provedena u višim razredima osnovne škole i tijekom srednje škole, gdje motivacija učenika za STEM dobro predviđa njihove aspiracije prema STEM karijerama (Hall, Dickerson, Batts, Kauffmann i Bosse, 2011). Vjerojatan razlog tomu jest spoznaja da motivacija učenika za STEM područje pada tijekom srednjoškolskih godina, a taj pad motivacije postaje rizičan faktor za niža postignuća u STEM školskim predmetima. Stoga niža postignuća u STEM predmetima, upravo u tom obrazovnom razdoblju, mogu utjecati na izbor nastavka školovanja u STEM području (npr. Maltese i Tai, 2011; Wang i Eccles, 2013).

U proučavanoj literaturi utvrđeno je da postoji nekoliko najčešće istraživanih moderacijskih varijabli koje bi mogle djelovati na veličinu učinka STEM intervencija. Ovdje ćemo se usmjeriti na rodne razlike među učenicima, dob učenika i razinu njihove početne motivacije za STEM područje.

Proučavajući rodne razlike, nisu pronađeni jednoznačni rezultati, pa je zaključeno da rod ne moderira sustavno učinak motivacijskih intervencija (Rosenzweig i Wigfield, 2016). Iz navedenoga može se očekivati da će buduće STEM intervencije biti podjednako učinkovite za učenike i učenice. Drugi potencijalni moderacijski efekt vezan je uz dob učenika. Iako nema dovoljno dokaza za donošenje čvrstih zaključaka da su intervencijski programi učinkovitiji kod učenika mlađe dobi, postoje određene spoznaje koje idu u prilog toj pretpostavci. Istraživanja pokazuju da motivacija i interesi za STEM područje opadaju tijekom viših razreda osnovne škole te se taj pad nastavlja i tijekom srednje škole (npr. Bryan, Glynn i Kittleson, 2011; Gottfried, Fleming i Gottfried, 2001; Osborne, Simon i Collins, 2003). Postoje i nalazi koji govore da profesionalni interesi poprimaju očekivanu i stabilnu strukturu u dobi od približno 14 godina (Tracey, 2002a; Tracey, Robbins i Hofsess, 2005; Tracey i Ward, 1998), što je potvrđeno i kod formiranja STEM interesa (Sadler, Sonnert, Hazari i Tai, 2012; Tai, Liu, Maltese i Fan, 2006). S obzirom na navedeno, očekivano je da će STEM intervencije biti učinkovitije ako budu uvedene tijekom formiranja interesa, odnosno prije nego što se oni stabiliziraju i učvrste. Idući moderacijski faktor jest početna razina motiviranosti učenika za STEM područje. Rezultati istraživanja uglavnom pokazuju da početna razina školskoga postignuća u STEM predmetima, kao i početna motivacija za STEM područje ima određene posljedice na učinkovitost intervencija. Kod učenika boljeg uspjeha i veće motivacije učinci STEM intervencija manji su u odnosu na učenike slabijeg uspjeha i motivacije (npr. Hong i Lin-Siegler, 2012; Hulleman i Harackiewicz, 2009). Vjerojatan razlog tomu jest postojanje efekta plafona kod početno zainteresiranih učenika.

Cilj je ovog istraživanja utvrditi učinkovitost intervencijskoga programa usmjerenog na povećanje motivacije osnovnoškolaca za STEM područje. U tu svrhu primijenjen je kvazi-eksperimentalni nacrt s eksperimentalnom i kontrolnom skupinom učenika te testiranjem nakon provedenoga programa. Pokušalo se utvrditi postoji li učinak programa na povećanje interesa učenika za STEM zanimanja te na promjenu stavova prema znanstvenicima u STEM području. Provjereni su i moderacijski efekti spola i dobi učenika (razred koji pohađa) te njihova prijašnjeg STEM školskog uspjeha na učinke intervencije. Testiranje prije početka tretmana nije bilo provedeno zbog organizacijskih razloga, a ujednačavanje ispitanika kon-

trolne i eksperimentalne skupine provelo se statističkom tehnikom uparivanja prema sklonosti (eng. *Propensity Score Matching*). Tehnika uparivanja prema sklonosti osigurava ujednačivanje kontrolne i eksperimentalne skupine po relevantnim obilježjima te omogućuje donošenje točnijih zaključaka o učincima tretmana u kvaziekperimentalnim nacrtima. Navedena tehnika ukratko je opisana u idućem poglavlju.

Tehnika uparivanja prema sklonosti

Istraživanja na području obrazovanja rijetko su organizirana i koncipirana kao čista eksperimentalna istraživanja s potpuno slučajnim odabirom ispitanika za skupine. Stoga su istraživači najčešće primorani rabiti kvaziekperimentalne nacрте kako bi utvrdili učinke određenih intervencija. Problem kvaziekperimentalnih nacрта leži u tome što postoje relevantni pozadinski faktori koji utječu na podjelu ili selekciju učenika u eksperimentalnu i kontrolnu skupinu, što dovodi do pristranosti rezultata i nalaza istraživanja. Jedan od načina minimalizacije takve pristranosti jest primjena tehnike uparivanja prema sklonosti. Tehnika uparivanja prema sklonosti razvijena je i prikazana prvi put u radu Rosenbauma i Rubina (1983) kao metoda koja omogućuje ujednačivanje nejednakih grupa upotrebom niza kovarijata reprezentiranih jednim skalarnim rezultatom. Ova se metoda pokazala vrlo učinkovitom u smanjenju pristranosti prilikom interpretacije učinaka različitih intervencija te korisnom metodom ujednačivanja grupa u kvaziekperimentalnim nacrtima (npr. Dehejia i Wahba, 2002; Luellen, Shadish i Clark, 2005). Ovu metodu preporučuje i američko ministarstvo obrazovanja, kako bi se poboljšala snaga nalaza kvaziekperimentalnih istraživanja (U. S. Department of Education, 2003). Tehnika uparivanja prema sklonosti ukratko je opisana u idućem poglavlju preko nekoliko osnovnih koraka (Caliendo i Kopeinig, 2008; Lane, To, Shelley i Henson, 2012).

U prvom koraku treba odabrati relevantne kovarijate koji su mogli utjecati na početnu neujednačenost skupina. Stoga sve teorijski relevantne varijable na osnovi kojih se može predvidjeti grupna pripadnost ispitanika kontrolnoj i eksperimentalnoj skupini treba identificirati te uključiti u procjenu tzv. *rezultata sklonosti* (eng. *propensity score*). Drugi je korak procjena *rezultata sklonosti* za svakog ispitanika na osnovi kovarijata. Taj je rezultat zapravo vjerojatnost pripadanja ispitanika kontrolnoj ili eksperimentalnoj skupini na osnovi rezultata na kovarijatima. Najčešća je tehnika primjena logističke regresije s kovarijatima kao prediktorima i dihotomnom varijablom grupne pripadnosti kao kriterijem (Austin, 2010; Shadish, Luellen i Clark, 2006). Pošto je izračunana predviđena vrijednost za svakog ispitanika (odnosno rezultat sklonosti), pristupa se

uparivanju ispitanika kontrolne i eksperimentalne skupine prema sličnosti njihovih rezultata. Postoji nekoliko metoda izračunavanja sličnosti između rezultata te nekoliko metoda uparivanja ispitanika. Te metode mogu varirati ovisno o nacrtu i cilju istraživanja, karakteristikama uzorka i obilježjima korištenih varijabli (za više informacija vidjeti Dehejia i Wahba, 2002; Stuart i Rubin, 2007). Cilj je uparivanja formiranje eksperimentalne i kontrolne skupine ispitanika koje su ujednačene po rezultatima na korištenim kovarijatima, odnosno skupina koje imaju slične distribucije rezultata sklonosti. Takvim se postupkom postiže ujednačenost skupina po svim dostupnim relevantnim obilježjima i postiže situacija poput one koja je teorijski ostvarena slučajnim raspoređivanjem ispitanika u grupe kod pravoga eksperimentalnog nacrta. Nakon formiranja ujednačenih skupina novoformirane skupine ispitanika uspoređuju se s obzirom na ostvarene rezultate na kriterijskoj varijabli. Statistički zaključci doneseni prilikom takve usporedbe trebali bi biti nepristrani i mogli bi se s većom sigurnosti pripisati djelovanju eksperimentalne intervencije, jer je potencijalna početna neujednačenost među skupinama po relevantnim obilježjima uklonjena uparivanjem.

METODA

Ispitanici

Uzorak škola obuhvaća osam eksperimentalnih i osam kontrolnih škola s područja grada Zagreba i zagrebačke županije. Iako se radilo o prigodnom uzorku škola, škole u eksperimentalnoj i kontrolnoj skupini odabrane su iz četiri klastera škola različite razine urbaniziranosti: 1) centar grada Zagreba; 2) gradska naselja; 3) naselja zagrebačkoga prstena, 4) gradovi Zagrebačke županije. Temelj takvoj klasterizaciji jesu dosadašnji nalazi o važnosti stupnja urbanizacije i razvijenosti okoline u kojoj se škola nalazi pri predviđanju školskoga postignuća (Babarović, Burušić i Šakić, 2009; Burušić, Babarović i Šakić, 2009). Po dvije ekvivalentne škole iz svakoga klastera činile su eksperimentalnu i kontrolnu skupinu, čime se pokušalo osigurati da škole u eksperimentalnoj i kontrolnoj skupini budu ekvivalentne s obzirom na socioekonomski status učenika. Nakon formiranja uzorka škola pristupilo se uzorkovanju razrednih odjela. U velikom broju škola postojala su samo dva razredna odjela u pojedinoj dobnoj kohorti, pa su u tim situacijama uzeti svi razredni odjeli. U situacijama s više razrednih odjela pristupilo se uzorkovanju tako da su odabrana ona dva razredna odjela koji sastavom učenika ne predstavljaju ekstreme s obzirom na školski uspjeh i socio-demografsku strukturu učenika. Konačan uzorak sačinjen je od onih učenika čiji su roditelji potpisali suglasnost za sudjelovanje u

istraživanju. U većini slučajeva prikupljene su suglasnosti roditelja, pa je realizirana veličina uzorka vrlo blizu njegovoj bruto veličini (95,3 % u eksperimentalnim i 84,4 % u kontrolnim školama). Konačan uzorak učenika eksperimentalnih škola činila su 303 učenika četvrtih, 295 učenika petih i 322 učenika šestih razreda, ukupno 920 učenika. Iz kontrolnih škola sudjelovalo je 296 učenika četvrtih, 271 učenik petih i 316 učenika šestih razreda, ukupno 883 učenika.

Za potrebe utvrđivanja učinkovitosti intervencije odabrani su samo oni učenici eksperimentalnih škola koji su sudjelovali u svim dijelovima intervencije, odnosno bili izloženi cjelokupnom intervencijskom tretmanu. Time je broj učenika eksperimentalnih škola uključenih u analize opao na 197 učenika četvrtih, 191 učenika petih i 213 učenika šestih razreda, odnosno na ukupno 601 učenika.

Postupak

STEM intervencija

STEM intervencija razvijena je za potrebe ovog istraživanja na osnovi iskustava programa osmišljenog na Sveučilištu u Zagrebu, Fakultetu elektrotehnike i računarstva (FER), pod imenom "ŠUZA – iz škole u znanost i akademsku zajednicu" (<https://www.suza.fer.hr>). Intervencija je provedena u obliku multidisciplinarnih radionica, edukativnih posjeta fakultetskim laboratorijima te predavanja u školama. Kroz njih su učenici imali priliku dobiti više informacija o STEM područjima, STEM zanimanjima, učiti ili dokazati neke od prirodnih i matematičkih zakona, ali i restrukturirati i integrirati prethodno naučeno. Intervencija je imala tri osnovna cilja: povećanje interesa učenika za STEM predmete, razvoj pozitivnih stavova prema STEM području te pružanje više informacija o izgledu STEM zanimanja. Unutar modela Rosenzweiga i Wigfielda (2016), nastojalo se najviše utjecati na učenička vjerovanja u vlastite kompetencije, njihove vrijednosti, interese i intrinzičnu motivaciju te na vjerovanja u vlastite sposobnosti. Dizajn većega dijela intervencije oslanjao se na *teorije iskustvenog učenja* (Kolb, Boyatzis i Mainemelis, 2001) te na *učenje vođeno propitkivanjem* (eng. *inquiry-guided learning*; Lee, Greene, Odom, Schechter i Slatta, 2004). U STEM intervencijama sudjelovali su učenici četvrtih, petih i šestih razreda iz osam eksperimentalnih škola.

Prvi dio

Od 13. do 22. siječnja 2016. godine u eksperimentalnim školama provedene su radionice u trajanju od jednoga školskog sata, a vodili su ih znanstvenici s FER-a. Kombinacijom više metoda poučavanja nastojalo se učenicima približiti dijelove STEM područja, potaknuti ih na razmišljanje i povećati njihovu zainteresiranost za znanost, tehnologiju i matematiku. Osnovni cilj radionice bio je prikazati što rade znanstvenici i

pokazati da je znanost zanimljiva. Pokušao se pokriti što širi spektar STEM područja, od matematike i fizike pa sve do programiranja i robotike. Učenici su upoznati s fraktalima, potencijama broja dva, programiranjem u vizualnom programskom jeziku Scratch, osnovama elektriciteta i elektromagnetizma, a prezentirani su im i LEGO programibilni roboti. Učenicima je predstavljena i online platforma Edmodo, na kojoj su za njih organizirane virtualne učionice i objavljeni dodatni sadržaji.

Drugi dio

Drugi dio intervencije proveden je od 3. do 26. veljače 2016., kada je organiziran odlazak učenika na FER, koji je trajao za svaku skupinu učenika približno tri sata. Znanstvenici s FER-a organizirali su niz aktivnosti kako bi učenicima pokazali čime se bave te ih zainteresirali za područje. Tijekom posjeta učenici su imali priliku vidjeti istraživačke laboratorije i zavode FER-a. Svaka grupa učenika posjetila je dva laboratorija ili zavoda i pobliže se upoznala s njihovim znanstvenim i nastavnim radom. Učenici su se upoznali s robotskim uređajima, humanoidnim robotima, svojstvima zvuka, naučili osnovne pojmove vezane uz obnovljive izvore energije, isprobali vožnju na samobalansirajućem biciklu te upravljali računalom pomoću "misli".

Osim predstavljanja laboratorija i zavoda, znanstvenici FER-a su za sve učenike osmislili i dvije radionice, svaku u trajanju od 45 minuta. Na radionici LEGO Mindstorms učenici su sastavili i programirali LEGO robota, naučivši neke osnovne robotike. U radionici programiranja učenici su iskusili programiranje na računalu. Koristeći se posebno odabranim obrazovnim računalnim igrama (eng. *edutainment*), učenici su intuitivno usvojili koncepte slijednoga programiranja, uvjetnih naredbi i petlji, a dio učenika i koncept potprograma. U interakciji s instruktorima, ti su koncepti osviješteni i podignuti na apstraktnu razinu algoritamskog rješavanja problema.

Treći dio

Treća radionica provedena je od 4. ožujka do 11. travnja 2016. godine u eksperimentalnim školama sa svakim razredom u trajanju od dva školska sata. Na ovoj radionici učenici su individualno i grupno rješavali zadatke izrađujući predmete i konstrukcije od papira. Time su iskustveno upoznali neke osnovne koncepte fizike, poput: sile, pritiska, poluge i čvrstoće. Cilj je ove radionice bio povećati interes učenika za STEM predmete i razviti pozitivne stavove prema STEM području.

Prikupljanje podataka anketnim upitnikom

Prikupljanje podataka anketnim upitnikom provedeno je nakon intervencije od 25. travnja do 4. svibnja 2016. godine. Anketiranje je trajalo dva školska sata, upitnik su ispunjavali svi

učenici uključeni u istraživanje, a provedeno je skupno u razredima tijekom redovite nastave u standardiziranim uvjetima. Upitnike su primijenili obučeni anketari koristeći se standardiziranom grupnom uputom i procedurom testiranja. Upitnik je podijeljen u dva dijela – jedna knjižica za svaki školski sat, a postojale su zasebne verzije upitnika za dječake i djevojčice.

Instrumenti

U ovom radu prikazani su rezultati prikupljeni upitnicima kojima su mjerene određene motivacijske dispozicije za STEM područje, a koji bi s obzirom na prirodu intervencije mogli poslužiti kao indikatori njezine učinkovitosti. To su: Skala stereotipa prema zaposlenima u STEM zanimanjima i Upitnik interesa za STEM karijere. Upotrijebljeni instrumenti manji su dio opsežnog upitnika koji su učenici ispunjavali.

Skala stereotipa prema zaposlenima u STEM zanimanjima adaptirana je iz projekta ASPIRES (Archer, DeWitt, Osborne, Dillon, Willis i Wong, 2014) i pripadajućih instrumenata. Skala se sastoji od osam tvrdnji, od koji se pet odnosi na pozitivne, a tri na negativne stereotipe prema zaposlenima u STEM području. Svaka čestica započinje frazom: "Ljudi koji rade kao znanstvenici, matematičari, inženjeri te se koriste računalima i novim tehnologijama u svojem poslu ..." i nastavlja se nekom pozitivnom (npr. su pametni) ili negativnom (npr. nemaju mnogo drugih interesa) tvrdnjom. Zadatak ispitanika bio je procijeniti slaganje s tvrdnjom na skali od pet stupnjeva. Eksploratornom faktorskom analizom (Metoda glavnih komponenta) utvrđeno je postojanje jasne dvofaktorske strukture podataka sa dva nezavisna faktora (*Varimax* rotacija). Pet čestica pozitivnih stereotipa visoko su saturirane prvom, a tri čestice koje mjere negativne stereotipe drugom glavnom komponentom (sve saturacije pripadajućom glavnom komponentom prelaze 0,65). Dobivena je zadovoljavajuća pouzdanost formiranih podskala ($\alpha = 0,78$ za podskalu pozitivnih i $\alpha = 0,73$ za podskalu negativnih stereotipa). Ove podskale rabit će se u daljnjim analizama.

Upitnik interesa za STEM karijere mjeri interese u pojedinačnim STEM područjima (te predstavlja adaptaciju novog upitnika *STEM Career Interest Survey* (STEM-CIS, Kier, Blanchard, Osborne i Albert, 2014). U hrvatskoj adaptiranoj inačici zadržano je 16 čestica, po četiri za svako STEM područje. Česticama se ispituje u kojoj se mjeri učenici namjeravaju baviti STEM područjem u svojoj karijeri, zanimaju li ih ta zanimanja i aktivnosti te imaju li podršku roditelja za takav izbor. Upitnik je formiran kao popis tvrdnji, a zadatak je ispitanika da na skali Likertova tipa procijene koliko se s navedenom tvrdnjom slažu. Eksploratorna faktorska analiza (metoda glavnih komponenta) uz kosokutnu Oblimin rotaciju pokazala je

jasnu četverofaktorsku strukturu upitnika s visokim faktor-
skim opterećenjima čestica pripadajućim faktorom ($r > 0,70$).
Korelacije među zadržanim faktorima ne prelaze $r = 0,49$, što
upućuje na relativnu divergentnost STEM područja. Pouz-
danosti pojedinih STEM podskala bile su redom: $\alpha_S = 0,87$, $\alpha_T =$
 $0,89$, $\alpha_E = 0,94$, $\alpha_M = 0,90$, što pokazuje njihovu vrlo visoku
pouzdanost.

Osim navedenih upitnika, u ovom istraživanju uzeti su i
ostali prikupljeni podaci o obilježjima učenika. To su varijable
koje bi mogle uzrokovati neujednačenost među skupinama
(tzv. kovarijati) te podaci o obilježjima učenika vezanim uz
promatrane moderatorske utjecaje. Uzeti su podaci o spolu
učenika (muško – žensko), razredu učenika (4., 5. ili 6.), dobi
učenika u trenutku testiranja, prosjeku ocjena na kraju prošle
školske godine (mjereno na dvije decimale), ocjeni iz matema-
tike na kraju prošle godine (1 do 5) kao mjeri STEM školskoga
postignuća¹ te obrazovanju majke i oca mjereno kao najviša
završena obrazovna razina svakoga od roditelja (1 – osnovna
škola; 2 – srednja škola; 3 – viša škola ili fakultet; 4 – magisterij
ili doktorat).

REZULTATI

Pri obradbi podataka uzet je programski paket IBM SPSS 22.0,
kojim su utvrđivane međugrupne razlike na kovarijatima (t-test,
hi-kvadrat test) i kriterijskim varijablama (MANOVA i ANOVA).
Za primjenu tehnike uparivanja prema sklonosti uzet je Excel
s dodatnim statističkim softverom XLSTAT.

Početak analize metodom uparivanja prema sklonosti te-
melji se na odabiru relevantnih kovarijata koji bi mogli utjecati
na početnu neujednačenost skupina. U provedenom istraži-
vanju kao kovarijati su uzeti spol ispitanika, njihova dob,
prosjeck ocjena i ocjena iz matematike te obrazovanje majke i
oca. Navedene varijable uključene su kao prediktori u logis-
tičku regresiju s kriterijskom varijablom pripadanja eksperi-
mentalnoj ili kontrolnoj skupini (kodirano kao 0 ili 1).

Na osnovi provedene logističke regresije može se proci-
jeniti učinak kovarijata na početnu grupnu pripadnost. Za
početak, može se usporediti uspješnost klasifikacije ispitanika
u grupe prije primjene logističke regresije i uspješnosti klasi-
fikacije na temelju logističke funkcije (modela). Početna klasi-
fikacija od 59,3 % pokazuje da je, s obzirom na prikupljene
podatke, u kontrolnoj skupini bilo 59,3 % učenika, što odgo-
vara apriornoj klasifikaciji. Na osnovi logističkoga modela,
uspješnost točnih predikcija porasla je na 63,1 %, što upućuje
na to da se na osnovi upotrijebljenih kovarijata točnost klasi-
fikacije može poboljšati za skromnih 3,8 %. Navedeno upuću-
je na prilično male razlike među skupinama s obzirom na
kovarijate, odnosno da su kontrolna i eksperimentalna skupi-

¹ Ocjena iz
matematike uzeta je
kao jedina mjera
postignuća u STEM
školskim predmetima,
jer učenici 4., 5. i 6.
razreda imaju jedino
matematiku kao STEM
predmet sustavno kroz
sva tri razreda.

● TABLICA 1
Rezultati logističke
regresije pri prognozi
pripadnosti kontrolnoj
i eksperimentalnoj
skupini na osnovi
kovarijata

Prediktor	<i>b</i>	<i>SE b</i>	Waldov χ^2	<i>df</i>	<i>p</i>	<i>exp. b</i>
Spol	-0,040	0,122	0,108	1	0,743	0,961
Dob	0,022	0,070	0,097	1	0,756	1,022
Matematika	0,976	0,142	47,203	1	0,000	2,653
Prosjeak	-1,768*	0,294	36,203	1	0,000	0,171
Obrazovanje majke			8,287	4	0,082	
Obrazovanje oca			6,953	4	0,138	
Značajnost cijeloga modela	χ^2			<i>df</i>		<i>p</i>
Goodness of Fit	67,672			12		0,000
-2 Log likelihood			1603,782			
Cox i Snell R^2			0,053			
Nagelkerke R^2			0,072			
Početna uspješnost klasifikacije			59,3 %			
Uspješnost klasifikacije na osnovi modela			63,1 %			

* Supresorski efekt preko ocjene iz matematike.

na već i prije primjene uparivanja prema sklonosti bile prilično ujednačene (Tablica 1). Test značajnosti modela ipak upućuje na statističku značajnost logističke funkcije $\chi^2(8) = 7,664$ ($p < 0,01$), odnosno da se grupe međusobno razlikuju barem po nekom od kovarijata. Iako značajne, te su razlike relativno male, jer koeficijenti koji upućuju na proporciju varijance grupe pripadnosti objašnjene kovarijatima ne prelaze 7,2 % (Cox i Snell $R^2 = 0,053$; Nagelkerke $R^2 = 0,072$). Značajnim kovarijatom pokazala se ocjena iz matematike, gdje su učenici kontrolne škole imali nešto bolje ocjene (Waldov $\chi^2(1) = 47,203$; $p < 0,01$). Opći prosjek ocjena također se pokazao značajnim prediktorom u modelu. Iako prosjek ocjena nije značajno povezan s kriterijskom varijablom ($r_{pb} = -0,022$; $p = 0,412$), njegov je doprinos modelu vjerojatno supresorski, gdje djeluje preko ocjene iz matematike s kojom je visoko povezan ($r = 0,875$; $p < 0,01$).

Početne razlike između ispitanika eksperimentalne i kontrolne skupine tada su provjerene primjenom t-testa za nezavisne uzorke, ako se radilo o intervalnim kovarijatima, odnosno hi-kvadrat testom u slučaju nominalnih kovarijata (Tablica 2). Ta je provjera važna zbog utvrđivanja veličine početne neujednačenosti među grupama i usporedbe s poboljšanom ujednačenosti nakon primjene uparivanja rezultata prema sklonosti. Rezultati pokazuju da su grupe bile početno neujednačene jedino po ocjeni iz matematike ($t(1459) = -2,97$; $p = 0,003$; $d = 0,16$), gdje je eksperimentalna skupina imala nešto lošiju prosječnu ocjenu ($M_E = 4,06$; $M_K = 4,21$).

Zatim je primijenjena metoda uparivanja rezultata prema sklonosti. Uparivanje na osnovi rezultata sklonosti provedeno je pomoću algoritma "greedy matching", koji sortira rezul-

tate eksperimentalne grupe prema njihovim rezultatima sklonosti (Y' iz logističke regresije) i sekvencijalno uparuje svakog ispitanika iz eksperimentalne grupe s ispitanicima kontrolne grupe s obzirom na sličnost rezultata sklonosti (Thoemmes i Kim, 2011). Odabrana metoda uparivanja bila je *jedan na jedan* (eng. *one-to-one*), pri čemu se svakom ispitaniku eksperimentalne grupe pridružuje po jedan, najbliži, ispitanik iz kontrolne. Uz navedeno, izračunana je i tzv. veličina *pomične mjerke* (eng. *caliper*) te je postavljena na razinu od 0,10 sigma kako bi se uparili samo oni ispitanici koji su bliski, odnosno slični. Ovako postavljena granica prilično je stroga i trebala bi rezultirati izjednačenim skupinama (Stuart, 2010). Kao rezultat primjene ovako postavljene metode dobivene su skupine od 498 učenika u svakoj od grupa.

Balansiranost novoformiranih grupa ispitanika po rezultatima na kovarijatima zatim je provjerena t-testovima u slučaju intervalnih varijabli te hi-kvadrat testovima u slučaju nominalnih kovarijata (Tablica 2). Utvrđeno je da nakon primjene metode uparivanja prema sklonostima nema statistički značajnih razlika među skupinama ni po jednom kovarijatu ($p > 0,05$). Time je metodološki ostvarena ujednačenost skupina prije eksperimentalne intervencije te je omogućeno donošenje objektivnijega zaključka o utjecaju tretmana na promatrane ishode.

● **TABLICA 2**
Jednakost kovarijata
prije i nakon
uparivanja prema
sklonosti

		Eksperimentalna grupa		Kontrolna grupa					
		<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>t</i>	<i>df</i>	<i>p</i>	<i>d</i>
Intervalni kovarijati									
Prije uparivanja	Dob	11,86	0,91	11,83	0,89	0,62	1359	0,538	0,03
	Matematika	4,06	0,96	4,21	0,93	-2,97	1459	0,003	0,16
	Prosjek	4,59	0,43	4,57	0,51	0,85	1367	0,398	0,05
Nakon uparivanja	Dob	11,85	0,91	11,86	0,89	-0,13	996	0,896	0,01
	Matematika	4,09	0,95	4,20	0,91	-1,76	996	0,080	0,11
	Prosjek	4,62	0,42	4,62	0,46	0,08	996	0,933	0,01
Nominalni kovarijati									
				χ^2	<i>df</i>	<i>p</i>			
Prije uparivanja	Spol			0,371	1	0,542			
	Obrazovanje majke			5,548	4	0,236			
	Obrazovanje oca			2,303	4	0,680			
Nakon uparivanja	Spol			0,825	1	0,364			
	Obrazovanje majke			4,927	4	0,295			
	Obrazovanje oca			4,651	4	0,325			

U Tablici 3 prikazani su učinci intervencije na stavove o znanstvenicima. Multivarijatnom analizom varijance provjeren je postojanje glavnih efekata intervencije, interakcijskih efekata intervencije s obzirom na spol i dob učenika te njihov

prethodni školski uspjeh iz matematike. Glavni učinci govore o razlikama između grupa po promatranom obilježju, dok interakcijski efekti govore o mogućem moderacijskom učinku nekoga od promatranih obilježja na ishod intervencije. Za potrebe ove analize uspjeh iz matematike dihotomiziran je, pa su jednu skupinu činili učenici s odličnim uspjehom (kodirano s 1; 59,4 % učenika), a drugu ostali učenici (kodirano sa 0). Dob se učenika u ovoj analizi odnosi na razred koji učenici pohađaju (4., 5., i 6.). Multivarijatna analiza pokazala je da se učenici eksperimentalne i kontrolne skupine razlikuju u stavovima prema znanstvenicima nakon provedene intervencije (*Wilks* $\Lambda = 0,993$; $p = 0,03$), no i da je efekt tretmana prilično malen ($\eta^2 = 0,01$). Univarijatnom analizom varijance pokazalo se da je utjecaj intervencije vezan samo uz male promjene u pozitivnim stavovima prema znanstvenicima ($F(1;975) = 4,48$; $p = 0,03$), koji su prosječno nešto viši u eksperimentalnoj skupini ($M_E = 3,94$; $M_K = 3,87$). Ni jedan od interakcijskih efekata nije pokazao multivarijatnu značajnost ($p > 0,05$), što se može interpretirati tako da su dobiveni glavni efekti neovisni o spolu, dobi i ranijem uspjehu učenika.

● **TABLICA 3**
Učinci intervencije na stavove prema znanstvenicima te moderacijski efekti spola, dobi i ocjene iz matematike (MANOVA)

	Eksperimentalna grupa		Kontrolna grupa		<i>Wilks</i> Λ	p	η^2	F	$df_1;df_2$	p	η^2
	M	SD	M	SD							
Glavni efekti											
Pozitivan stav prema znanstvenicima	3,94	0,79	3,87	0,75	0,993	0,03	0,01	4,48	1;975	0,03	0,00
Negativan stav prema znanstvenicima	2,89	0,98	2,97	0,99				1,74	1;975	0,19	0,00
Moderacijski efekti											
Vrsta škole x spol					0,996	0,16	0,00				
Vrsta škole x dob					0,996	0,43	0,00				
Vrsta škole x mat.*					0,994	0,06	0,01				

* Mat. – dihotomizirana ocjena iz matematike.

Učinci intervencije na profesionalne interese učenika u STEM području testirani su na isti način i uz provjeru utjecaja istih moderatorskih varijabli. U ovom slučaju postojale su četiri zavisne varijable – interesi za zanimanja na području znanosti, matematike, tehnologije i inženjerstva (Tablica 4). Multivarijatna analiza značajnosti glavnog efekta intervencije nije se pokazala značajnom (*Wilks* $\Lambda = 0,992$; $p = 0,08$), što pokazuje da intervencija nije imala značajan utjecaj na promjenu STEM interesa kod učenika eksperimentalne skupine u odnosu na kontrolnu. Ipak, analizom interakcijskih efekata ustanovilo se da postoji malen, ali značajan, multivarijatni efekt dobi učenika kao moderatora promatranog učinka (*Wilks* $\Lambda = 0,980$; $p = 0,01$; $\eta^2 = 0,01$).


	Eksperimentalna grupa		Kontrolna grupa		Wilks			F	df1;df2	p	η^2
	M	SD	M	SD	Λ	p	η^2				
Glavni efekti											
Znanost	2,77	1,18	2,66	1,18	0,992	0,08	0,01				
Matematika	2,88	1,26	2,71	1,22							
Tehnologija	3,12	1,20	3,08	1,24							
Inženjerstvo	2,40	1,24	2,15	1,17							
Moderacijski efekti											
Vrsta škole x spol					0,994	0,23	0,01				
Vrsta škole x dob					0,980	0,01	0,01				
Znanost								0,80	2;975	0,45	0,00
Matematika								6,12	2;975	0,00	0,01
Tehnologija								5,54	2;975	0,00	0,01
Inženjerstvo								1,76	2;975	0,17	0,00
Vrsta škole x mat.*					0,998	0,75	0,00				

* Mat. – dihotomizirana ocjena iz matematike.


❶ **TABLICA 4**
Učinci intervencije na interese učenika prema STEM područjima te moderacijski efekti spola, dobi i ocjene iz matematike (MANOVA)

Značajan interakcijski efekt vezan je uz povećanje interesa za matematiku ($F(2;975) = 6,12; p < 0,01$) i tehnologiju ($F(2;975) = 5,54; p < 0,01$) kod nekih dobnih skupina unutar eksperimentalne skupine. Moderacijski efekt dobi na interese s područja matematike vidi se na Slici 1, a na interese na području tehnologije na Slici 2. U oba prikaza vidi se da postoji razlika između kontrolne i eksperimentalne skupine u profesionalnim interesima u najmlađoj dobnj grupi (4. razredi) te da se taj efekt gubi u starijoj dobi (5. i 6. razredi). Dobiveni nalaz upućuje na zaključak da je intervencija imala određen pozitivni učinak na povećanje STEM interesa unutar ova dva područja, ali samo kod učenika mlađe dobi.

➡ **SLIKA 1**
Moderacijski efekt dobi učenika na učinke intervencije na profesionalne interese na području matematike



➔ SLIKA 2
Moderacijski efekt
dobi učenika na
učinke intervencije na
profesionalne interese
na području
tehnologije



RASPRAVA

Na osnovi dobivenih rezultata može se zaključiti da je provedena STEM intervencija imala određene pozitivne efekte na stavove učenika osnovnih škola prema znanstvenicima. Taj se efekt vidi u malom povećanju pozitivnih stavova prema znanstvenicima kod eksperimentalne skupine u odnosu na kontrolnu nakon provedene intervencije. Intervencija, s druge strane, nije pokazala značajan učinak u smanjenju negativnih stavova prema znanstvenicima, iako dobivene aritmetičke sredine grupa upućuju na tendenciju njihova smanjenja kod eksperimentalne grupe u odnosu na kontrolnu. Potencijalni razlog nedobivanja značajnog efekta STEM intervencije kod negativnih stavova može biti u malom broju čestica kojima je operacionaliziran konstrukt (samo 3 pitanja) te nešto nižoj pouzdanosti te skale ($\alpha = 0,73$).

Povećanje pozitivnih stavova prema znanstvenicima u STEM području bilo je očekivano zbog samoga sadržaja intervencije, gdje su znanstvenici bili u izravnom kontaktu s učenicima i demonstrirali svoje područje rada kroz zanimljive radionice i eksperimente. Samim tim djelovali su na stavove učenika prema tim zanimanjima i osobama zaposlenim u tom području te na razbijanje potencijalno prisutnih stereotipa. Smatramo da je promjena stavova prema znanstvenicima bitan faktor u povećanju interesa za STEM područje i da intervencije usmjerene prema promjeni takvih stavova mogu potaknuti razvoj karijere učenika prema STEM području. Prijašnja istraživanja pokazala su da odluka o tome želi li se učenik baviti STEM zanimanjima ovisi i o slici koju učenik ima o osobama koje se tim zanimanjem bave i o tome može li učenik zamisliti sebe kao osobu koja se bavi STEM područjem (Bennett i Hogarth, 2009; Gilbert i Calvert, 2003).

Što se tiče moderacijskih efekata, dobiveno je da intervencija podjednako djeluje na stavove učenika različite dobi i spola te na učenike različita inicijalnog školskog postignuća iz matematike. Nepostojanje moderacijskog efekta spola donekle je u skladu sa zaključcima izvedenim iz prijašnjih istraživanja (Rosenzweig i Wigfield, 2016). Nalaz o jednakom učinku intervencije na učenike različita predznanja iz STEM područja odudara od očekivanja da će efekti biti veći kod učenika nižega inicijalnog postignuća (npr. Hulleman i Harackiewicz, 2009; Hong i Lin-Siegler, 2012). Moguć je razlog jednostruka operacionalizacija moderatorske varijable u ovom istraživanju, koja se zbog različite dobi učenika i školskoga kurikulum(a) u promatranim razredima svela samo na ocjenu iz matematike. Također, dihotomizacija postignuća učenika iz matematike u samo dvije kategorije (izvršni i ostali) mogla je dovesti do smanjenja varijabiliteta u moderatoru, pa onda i do manjeg učinka interakcije u regresijskom modelu. Stoga smatramo da bi učinak ovoga moderacijskog efekta trebalo promatrati preko ocjena iz više STEM školskih predmeta, ali i putem objektivnih mjera STEM znanja zbog potencijalne neobjektivnosti školskih ocjena (npr. Parkes, 2000; Wikström, 2005) i česte negativne zakrivljenosti njihove distribucije (dobiveno i u ovom istraživanju). Nalaz o podjednakom učinku intervencije na stavove prema znanstvenicima kod učenika različite dobi također nije potpuno očekivan, jer se pretpostavljalo da će učinci intervencije biti nešto veći kod mlađih učenika zbog slabije strukturiranih i formiranih STEM interesa (Tai i sur., 2006; Sadler i sur., 2012) na koje se potencijalno može u većoj mjeri djelovati. Međutim, budući da se ovdje radi tek o posrednoj varijabli (stavovi prema znanstvenicima) koja nije izravna mjera STEM interesa te relativno mladim kohortama učenika kod kojih profesionalni interesi još nisu jasno formirani (Tracey, 2002a; Tracey i sur., 2005; Tracey i Ward, 1998), ovakvi su nalazi interpretabilni.

Na osnovi dobivenih rezultata važno je zaključiti i da su intervencije usmjerene prema promjeni stavova prema znanstvenicima primjenjive na sve dobne skupine učenika osnovnih škola, da djeluju podjednako na dječake i djevojčice te one višega i nižega ranijeg STEM postignuća. Implikacije takvih nalaza upućuju na korisnost primjene ovakvih intervencija za sve učenike kroz različite razrede osnovne škole. Ipak, treba istaknuti da su učinci relativno maleni i da bi se potencijalno veći efekti mogli očekivati kod dugotrajnijih i sveobuhvatnijih intervencija provedenih unutar školskoga kurikulum(a), poput redovitih posjeta učenika znanstvenim institucijama i tehnološkim centrima, koji bi se temeljili na izravnim kontaktima sa znanstvenicima i istraživačima.

Učinci intervencije na povećanje profesionalnih interesa prema karijerama u STEM područjima skromni su. Prisutni su samo kod najmlađe skupine učenika (4. razredi), i to samo na području matematike i tehnologije. Potencijalni razlozi relativno slabog učinka intervencija na povećanje STEM interesa mogu se pronaći u samoj mjeri interesa iskorištenoj u ovom radu. Naime, Upitnik interesa za STEM karijere mjeri opće interese prema STEM područjima te u bitnome odudara od klasičnih i najčešćih mjera profesionalnih interesa, poput Hollandovih upitnika (npr. Self-Directed Search; Holland, 1985) ili Traceyeva upitnika Personal Globe Inventory (Tracey, 2002b). Navedeni upitnici mjere interese preko sviđanja jasno opisanih aktivnosti i konkretnih zanimanja te procjeni uspješnosti u njima. Takav pristup mjerenju interesa izravniji je i primjereniji mlađim učenicima. Pitanja iz ovdje primijenjenog upitnika, gdje se interes za STEM karijere u npr. području inženjerstva mjeri česticama poput "Namjeravam se baviti inženjerskim zanimanjem" i "Interesiraju me inženjerska zanimanja", mnogo su apstraktnija i zahtijevaju od učenika razumijevanje svakoga od STEM područja, njegova sadržaja i opsega. Osim toga, provedena se intervencija temeljila na vrlo praktičnim radionicama i eksperimentima, gdje su učenici bili u izravnoj interakciji sa znanstvenicima iz konkretnih STEM zanimanja (fizičari, kemičari, elektrotehničari, programeri). Zato vjerujemo da bi mjere utemeljene na sviđanju i procjeni uspješnosti u konkretnim aktivnostima i zanimanjima bolje artikulirale efekte intervencije kod osnovnoškolaca od apstraktnije procjene interesa na razini STEM područja.

Nalaz da je intervencija imala stanovit učinak na povećanja STEM interesa, ali samo kod učenika mlađe dobi, donekle odgovara ranije navedenim očekivanjima vezanim uz dob formiranja interesa. Očekivano je da će se stabilna i diferencirana struktura interesa kod učenika hrvatskih osnovnih škola potvrditi u dobi od 14 godina (Šverko, 2008; Šverko i Barbarović, 2006), ali i da postoje neke indikacije da se interes za STEM područje razvija i stabilizira čak i ranije, odnosno tijekom viših razreda osnovne škole (Tai i sur., 2006; Sadler sur., 2012). U svjetlu navedenih istraživanja, moguće je da ovako postavljena intervencija ima nešto veće efekte na STEM interese učenika mlađe osnovnoškolske dobi. Kod učenika od 10 do 11 godina (4. razred) STEM interesi sigurno nisu jasno strukturirani i stabilni, pa intervencija može imati veće efekte. Ipak, STEM intervencije u višim razredima osnovne škole mogu imati određene učinke na održavanje interesa za STEM područje, vjerojatno više nego na njihovo povećavanje. Naime, veći broj istraživanja pokazuje da mlađa djeca prvotno imaju visoku razinu interesa za znanost i matematiku, ali da se prolaskom kroz obrazovni sustav ovaj interes smanjuje, pose-

bice kod djevojčica (npr. Mitchell i Hoff, 2006; Riegler-Crumb, Moore i Ramos-Wada, 2011). Zato smatramo da provođenje STEM intervencija tijekom viših razreda osnovne škole može biti zaštitni faktor usmjeren prema održavanju interesa učenika prema STEM području.

U završnom dijelu rasprave osvrnut ćemo se na određena ograničenja dobivenih nalaza i na neke smjernice za buduća istraživanja na ovom području. Od ograničenja, u prvom redu treba naglasiti da dosezi obrazovnih intervencija u velikoj mjeri ovise o njihovu konkretnom sadržaju, organizaciji i trajanju. Zato dobivene rezultate treba promatrati kroz prizmu konkretne STEM intervencije, koja je bila relativno kratkotrajna, grupno organizirana, a participacija u njoj nije bila dobrovoljna, nego su svi učenici eksperimentalnih razreda sudjelovali u njoj. S druge strane, odabir zavisnih, odnosno ishodišnih, mjera također predstavlja mogući limitirajući faktor dosega učinka tretmana (ranije u raspravi). Zato dobiveni nalazi imaju donekle ograničenu vanjsku valjanost, odnosno mogućnost poopćavanja na druge slične intervencije, ispitnike i mjere. Nadalje, važno je spomenuti i ograničenja same metode uparivanja prema sklonosti. Uparivanje i ujednačavanje ispitanika kontrolne i eksperimentalne skupine bit će onoliko dobro koliko je odabrani set varijabli na osnovi kojih se provodi ujednačavanje relevantan za ishode tretmana. U ovom su istraživanju kao kovarijati uzeti dob, ocjene i spol učenika te obrazovanje roditelja. No postoji niz drugih potencijalnih faktora, poput stavova, interesa, slobodnih aktivnosti učenika ili obilježja nastavnika i škola, koji nisu obuhvaćeni ovim istraživanjem. Zato se uvijek, kod primjene metode uparivanja prema sklonosti, dobivene (ili nedobivene) razlike među skupinama nakon tretmana trebaju interpretirati s kritičkim osvrtom na tip i sadržaj upotrijebljenih kovarijata. Ipak, kada govorimo o smjernicama za buduća istraživanja učinaka obrazovnih intervencija primjenom kvaziekperimentalnih nacrti, treba svakako naglasiti korisnost primjene metode uparivanja prema sklonosti. Opis metode, njezina primjena te prikaz i interpretacija rezultata u ovom radu mogu poslužiti kao model njezine uporabe u drugim primijenjenim istraživanjima na području obrazovanja.

ZAKLJUČAK

Provedena STEM intervencija za učenike od četvrtog do šestog razreda osnovnih škola imala je skromne, no značajne, učinke na porast pozitivnih stavova prema znanstvenicima u STEM području. Dobiveni učinci pokazali su se stabilnima kod dječaka i djevojčica, učenika različite dobi te učenika višega i nižega školskog uspjeha iz matematike. Učinci STEM intervencije na povećanje interesa za STEM karijere pokazali

su se također skromnima i značajnima, ali samo kod učenika četvrtih razreda, odnosno u najmlađoj dobnoj skupini. Dobi-veno povećanje interesa za STEM karijere kod mlađih učenika također je neovisno o njihovu spolu i ranijem školskom uspjehu. Rezultati upućuju na pozitivne, premda niske, učinke STEM intervencije u osnovnim školama te na korisnost primjene ovakvih intervencija već u nižim razredima. Buduće intervencije trebale bi uključivati učenike različite dobi, podjednako dječake i djevojčice, te učenike različita školskog uspjeha iz STEM predmeta. Kako bismo povećali učinkovitost STEM intervencija, preporučujemo da one traju dulje te da zbog svoje sveobuhvatnosti budu inkorporirane u školski kurikulum (um) interaktivnim radionicama, eksperimentima ili praktičnim vježbama unutar školskih predmeta. Mogle bi se realizirati i kao međupredmetne teme i obvezne školske aktivnosti posjetima institucijama i tvrtkama koje zapošljavaju STEM stručnjake i istraživače.

Nadalje, ovim se radom pokušala demonstrirati primjena metode uparivanja prema sklonosti kao preporučljiva metoda statističkog ujednačavanja ispitanika eksperimentalne i kontrolne skupine u kvaziekperimentalnim nacrtima. Vjerujemo da će ova metoda naći svoju primjenu u istraživanjima u Hrvatskoj te postati standardni način provjere učinaka raznih intervencija u našem obrazovnom sustavu.

LITERATURA

Archer, L., DeWitt, J., Osborne, J., Dillon, J., Willis, B. i Wong, B. (2014). *ASPIRES. Young people's science and career aspirations, age 10–14*. London: Kings College London, Department of Education & Professional Studies.

Austin, P. (2010). The performance of different propensity-score methods for estimating differences in proportions (risk differences or absolute risk reduction) in observational studies. *Statistics in Medicine*, 29(20), 2137–2148. <https://doi.org/10.1002/sim.3854>

Babarović, T., Burušić, J. i Šakić, M. (2009). Uspješnost predviđanja obrazovnih postignuća učenika osnovnih škola Republike Hrvatske. *Društvena istraživanja*, 18(4-5), 673–695.

Bennett, J. i Hogarth, S. (2009). Would you want to talk to a scientist at a party? High school students' attitudes to school science and to science. *International Journal of Science Education*, 31(14), 1975–1998. <https://doi.org/10.1080/09500690802425581>

Bryan, R. R., Glynn, S. M. i Kittleson, J. M. (2011). Motivation, achievement, and advanced placement intent of high school students learning science. *Science Education*, 95(6), 1049–1065. <https://doi.org/10.1002/sce.20462>

Burušić, J., Babarović, T. i Šakić, M. (2009). Odrednice uspješnosti osnovnih škola u Republici Hrvatskoj: rezultati empirijske provjere. *Društvena istraživanja*, 18(4-5), 605–624.

Caliendo, M. i Kopeinig, S. (2008). Some practical guidance for implementation of propensity score matching. *Journal of Economic Surveys*, 22(1), 31–72. <https://doi.org/10.1111/j.1467-6419.2007.00527.x>

Caprile, M., Palmén, R., Sanz, P i Dente, G. (2015). *Encouraging STEM studies: Labour market situation and comparison of practices targeted at young people in different member states*. European Parliament's Committee on Employment and Social Affairs. Brussels, European Commission.

Dehejia, R. H. i Wahba, S. (2002). Propensity score-matching methods for nonexperimental causal studies. *Review of Economics and Statistics*, 84(1), 151–161. <https://doi.org/10.1162/003465302317331982>

European Commission (2004). *Europe needs more scientists: Report by the High Level Group on Increasing Human Resources for Science and Technology*. Brussels, European Commission.

Gilbert, J. i Calvert, S. (2003). Challenging accepted wisdom: Looking at the gender and science education question through a different lens. *International Journal of Science Education*, 25(7), 861–878. <https://doi.org/10.1080/09500690305030>

Gottfried, A. E., Fleming, J. S. i Gottfried, A. W. (2001). Continuity of academic intrinsic motivation from childhood to late adolescence: A longitudinal study. *Journal of Educational Psychology*, 82(3), 525–538. <https://doi.org/10.1037/0022-0663.82.3.525>

Hall, C., Dickerson, J., Batts, D., Kauffmann, P i Bosse, M. (2011). Are we missing opportunities to encourage interest in STEM? *Journal of Technology Education*, 23(1), 32–46. <https://doi.org/10.21061/jte.v23i1.a.4>

Holland, J. L. (1985). *The Self-Directed Search Professional Manual-1985 Edition*. Odessa: PAR.

Hong, H.-Y. i Lin-Siegler, X. (2012). How learning about scientists' struggles influences students' interest and learning in physics. *Journal of Educational Psychology*, 104(2), 469–484. <https://doi.org/10.1037/a0026224>

Hulleman, C. S. i Harackiewicz, J. M. (2009). Promoting interest and performance in high school science classes. *Science*, 326(5958), 1410–1412. <https://doi.org/10.1126/science.1177067>

Kier, M. W., Blanchard, M. R., Osborne, J. W. i Albert, J. L. (2014). The development of the STEM Career Interest Survey (STEM-CIS). *Research in Science Education*, 44(3), 461–481. <https://doi.org/10.1007/s11165-013-9389-3>

Kolb, D. A., Boyatzis, R. E. i Mainemelis, C. (2001). Experiential learning theory: Previous research and new directions. Perspectives on thinking, learning, and cognitive styles. *The Educational Psychology Series*, 1(8), 227–247.

Lane, F. C., To, Y. M., Shelley, K. i Henson, R. K. (2012). An illustrative example of propensity score matching with education research. *Career and Technical Education Research*, 37(3), 187–212. <https://doi.org/10.5328/cter37.3.187>

Lee, V. S., Greene, D. B., Odom, F., Schechter, E. i Slatta, R. W. (2004). What is inquiry-guided learning? U V. S. Lee (Ur.), *Teaching and learning through inquiry: A guidebook for institutions and instructors* (str. 3–16). Sterling, VA: Stylus.

DRUŠ. ISTRAŽ. ZAGREB
GOD. 27 (2018), BR. 4,
STR. 583-604

BABAROVIĆ, T.,
PALE, P., BURUŠIĆ, J.:
UČINCI STEM...

Luellen, J. K., Shadish, W. R. i Clark, M. H. (2005). Propensity scores. An introduction and experimental test. *Evaluation Review*, 29(6), 530–558. <https://doi.org/10.1177/0193841X05275596>

Maltese, A. V. i Tai, R. H. (2011). Pipeline persistence: Examining the association of educational experiences with earned degrees in STEM among U.S. students. *Science Education*, 95(5), 877–907. <https://doi.org/10.1002/sce.20441>

Mitchell, S. N. i Hoff, D. L. (2006). (Dis) Interest in science: How perceptions about grades may be discouraging girls. *Electronic Journal of Science Education*, 11(1), 10–21.

Osborne, J. i Dillon, J. (2008). *Science education in Europe: Critical reflections*. London: The Nuffield Foundation.

Osborne, J., Simon, S. i Collins, S. (2003). Attitudes towards science: A review of the literature and its implications. *International Journal of Science Education*, 25(9), 1049–1079. <https://doi.org/10.1080/095006903200032199>

Parkes, J. (2000). The relationship between reliability and cost of performance assessments. *Education Policy Analysis Archives*, 8(16), 1–14. <https://doi.org/10.14507/epaa.v8n16.2000>

Riegle-Crumb, C., Moore, C. i Ramos-Wada, A. (2011). Who wants to have a career in science or math? Exploring adolescents' future aspirations by gender and race/ethnicity. *Science Education*, 95(3), 458–476. <https://doi.org/10.1002/sce.20431>

Rosenbaum, P. R. i Rubin, D. B. (1983). The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1), 41–55. <https://doi.org/10.1093/biomet/70.1.41>

Rosenzweig, E. Q. i Wigfield, A. (2016). STEM motivation interventions for adolescents: A promising start, but further to go. *Educational Psychologist*, 51(2), 146–163. <https://doi.org/10.1080/00461520.2016.1154792>

Sadler, P. M., Sonnert, G., Hazari, Z. i Tai, R. (2012). Stability and volatility of STEM career interest in high school: A gender study. *Science Education*, 96(3), 411–427. <https://doi.org/10.1002/sce.21007>

Shadish, W. R., Luellen, J. K. i Clark, M. H. (2006). Propensity scores and quasi-experiments: A testimony to the practical side of Lee Sechrest. U R. R. Bootzin i P. E. McKnight (Ur.), *Strengthening research methodology: Psychological measurement and evaluation* (str. 143–157). Washington, DC: American Psychological Association.

Stuart, E. A. (2010). Matching methods for causal inference: A review and a look forward. *Statistical Science*, 25(1), 1–21. <https://doi.org/10.1214/09-STS313>

Stuart, E. A. i Rubin, D. B. (2007). Best practices in quasi-experimental designs: Matching methods for causal inference. U J. Osborne (Ur.), *Best practices in quantitative social science* (str. 155–176). Thousand Oaks, CA: Sage Publications.

Šverko, I. (2008). Spherical model of interests in Croatia. *Journal of Vocational Behavior*, 72(1), 14–24. <https://doi.org/10.1016/j.jvb.2007.10.001>

Šverko, I. i Babarović, T. (2006). The validity of Holland's theory in Croatia. *Journal of Career Assessment*, 14(4), 490–507. <https://doi.org/10.1177/1069072706288940>

DRUŠ. ISTRAŽ. ZAGREB
GOD. 27 (2018), BR. 4,
STR. 583-604

BABAROVIĆ, T.,
PALE, P., BURUŠIĆ, J.:
UČINCI STEM...

Tai, R. T., Liu, C. Q., Maltese, A. V. i Fan, X. T. (2006). Planning early for careers in science. *Science*, 312(5777), 1143–1144. <https://doi.org/10.1126/science.1128690>

Thoemmes, F. i Kim, E. S. (2011). A systematic review of propensity score methods in the social sciences. *Multivariate Behavioral Research*, 46(1), 90–118. <https://doi.org/10.1080/00273171.2011.540475>

Tracey, T. J. G. (2002a). Development of interests and competency beliefs: A 1-year longitudinal study of fifth- to eighth-grade students using the ICA-R and structural equation modeling. *Journal of Counseling Psychology*, 49(2), 148–163. <https://doi.org/10.1037/0022-0167.49.2.148>

Tracey, T. J. G. (2002b). Personal Globe Inventory: Measurement of the spherical model of interests and competence beliefs [Monograph]. *Journal of Vocational Behavior*, 60(1), 113–172. <https://doi.org/10.1006/jvbe.2001.1817>

Tracey, T. J. G., Robbins, S. B. i Hofsess, C. D. (2005). Stability and change in adolescence: A longitudinal analysis of interests from grades 8 through 12. *Journal of Vocational Behavior*, 66(1), 1–25. <https://doi.org/10.1016/j.jvb.2003.11.002>

Tracey, T. J. i Ward, C. C. (1998). The structure of children's interests and competence perceptions. *Journal of Counseling Psychology*, 45(3), 290–303. <https://doi.org/10.1037/0022-0167.45.3.290>

U. S. Department of Education, Institute of Educational Sciences (2003). *Identifying and implementing educational practices supported by rigorous evidence: A user friendly guide*. Washington, DC: Institute of Education Sciences.

Wang, M. i Eccles, J. S. (2013). School context, achievement motivation, and academic engagement: A longitudinal study of school engagement using a multidimensional perspective. *Learning and Instruction*, 28, 12–23. <https://doi.org/10.1016/j.learninstruc.2013.04.002>

Wikström, C. (2005). *Criterion-referenced measurement for educational evaluation and selection*. Umea, Sweden: Umea University, Department of Educational Measurement.

The Effects of the Elementary School STEM Intervention Program on Students' Attitudes and Interests: The Application of Propensity Score Matching Technique

Toni BABAROVIĆ
Institute of Social Sciences Ivo Pilar, Zagreb

Predrag PALE
Faculty of Electrical Engineering and Computing, Zagreb

Josip BURUŠIĆ
Institute of Social Sciences Ivo Pilar, Zagreb

There is a growing number of interventions intended to increase students' STEM school achievement and their interests in STEM careers. Conjointly, various methodological challenges in designing, implementation and evaluation of

DRUŠ. ISTRAŽ. ZAGREB
GOD. 27 (2018), BR. 4,
STR. 583-604

BABAROVIĆ, T.,
PALE, P., BURUŠIĆ, J.:
UČINCI STEM...

STEM interventions are recognized. In this paper, we evaluated the effectiveness of one STEM intervention by means of a quasi-experimental research design, on the sample of 1484 elementary school students, age 10 to 12 years. The effectiveness of the intervention was measured by change in attitudes toward scientists and by change in STEM interests. We used the Propensity Score Matching (PSM) technique to evaluate the effectiveness of the intervention. The results showed that the STEM intervention modestly increased positive attitudes toward scientists in the whole sample, and increased STEM interests of the youngest students. The research has also shown that the PSM technique has its application in evaluation studies of different educational interventions.

Keywords: STEM, effectiveness of intervention, Propensity Score Matching, attitudes toward scientists, interests in STEM



Međunarodna licenca / International License:
[Imenovanje-Nekomercijalno / Attribution-NonCommercial](#)