

# SADRŽAJ

<b>POGLAVLJE 1. UVOD U ISTRAŽIVANJE .....</b>	<b>4</b>
1.1. ZAŠTO ISTRAŽIVATI ISTRAŽIVAČKO UČENJE? .....	4
1.2. ZAŠTO U ISTRAŽIVANJU ISTRAŽIVAČKOG UČENJA KORISTITI OKVIR SAMOREGULIRAJUĆEG UČENJA? .....	8
1.3. METODOLOŠKI PRISTUP ISTRAŽIVANJU .....	10
<b>POGLAVLJE 2. PREGLED REZULTATA ISTRAŽIVANJA U PODRUČJU (SAMOREGULIRAJUĆEG) ISTRAŽIVAČKOG UČENJA.....</b>	<b>13</b>
<b>I. DIO: PREGLED PODRUČJA ISTRAŽIVANJA ZNANSTVENOG RAZMIŠLJANJA I ISTRAŽIVAČKOG UČENJA .....</b>	<b>14</b>
2.1. ŠTO JE ZNANSTVENO RAZMIŠLJANJE? .....	14
2.2. GLAVNI PRISTUPI ISTRAŽIVANJIMA ZNANSTVENOG RAZMIŠLJANJA .....	16
2.2.1. <i>Taksonomija istraživanja znanstvenog razmišljanja</i> .....	18
2.3. INTEGRATIVNI PRISTUP ISTRAŽIVANJIMA ZNANSTVENOG RAZMIŠLJANJA .....	21
2.3.1. <i>Zadaci</i> .....	21
2.3.2. <i>Rezultati istraživanja unutar integrativnog pristupa</i> .....	24
2.4. ISTRAŽIVAČKO UČENJE I MOTIVACIJSKI I EMOCIONALNI ASPEKTI UČENJA: IMPLIKACIJE ZA ISTRAŽIVANJE .....	40
<b>II. DIO: PREGLED PODRUČJA ISTRAŽIVANJA ISTRAŽIVAČKOG UČENJA KAO SAMOREGULIRAJUĆEG UČENJA .....</b>	<b>42</b>
2.5. SAMOREGULIRAJUĆE UČENJE: KONCEPTUALNO ODREĐENJE.....	42
2.6. SASTAVNICE SAMOREGULIRAJUĆEG UČENJA .....	45
2.6.1. <i>Metakognicija i samoregulirajuće učenje</i> .....	46
2.6.2. <i>Motivacija i samoregulirajuće učenje</i> .....	53
2.7. MJERENJE SAMOREGULIRAJUĆEG UČENJA .....	57
2.8. ISTRAŽIVAČKO UČENJE KAO SAMOREGULIRAJUĆE UČENJE: IMPLIKACIJE ZA ISTRAŽIVANJE .....	64
<b>POGLAVLJE 3. CILJ ISTRAŽIVANJA I ISTRAŽIVAČKI PROBLEMI .....</b>	<b>67</b>
<b>POGLAVLJE 4. METODOLOGIJA ISTRAŽIVANJA .....</b>	<b>70</b>
4.1. ISPITANICI.....	70
4.2. OPIS ZADATKA.....	77
4.3. OPIS SUČELJA I POSTUPKA RADA U PROGRAMU FILE.....	82
4.4. TIJEK ISTRAŽIVANJA I POSTUPAK .....	84
4.4.1. <i>Grupni sastanak</i> .....	84
4.4.2. <i>Individualno ispitivanje u programu FILE</i> .....	85
4.5. MJERNI INSTRUMENTI I KORIŠTENE MJERE.....	89
4.5.1. <i>Metakognitivno znanje</i> .....	91
4.5.2. <i>Metakognitivni doživljaj</i> .....	97
4.5.3. <i>Motivacija i emocionalno stanje</i> .....	98
4.5.4. <i>Istraživačke (kognitivne) vještine i strategije</i> .....	99
4.5.5. <i>Metakognitivne vještine</i> .....	105
4.5.6. <i>Stečeno znanje o kauzalnoj strukturi modela zadatka (učinak na zadatku)</i> .....	107
4.6. ANALIZA PODATAKA .....	110
4.6.1. <i>Priprema podataka za analizu</i> .....	110
4.6.2. <i>Kvantitativna analiza podataka</i> .....	113
<b>POGLAVLJE 5. REZULTATI I RASPRAVA .....</b>	<b>115</b>
<b>I. DIO: PROMJENE U PROCESIMA ISTRAŽIVAČKOG UČENJA IZMEĐU ČETIRI MJERENJA: ANALIZA SKUPNIH REZULTATA .....</b>	<b>117</b>
5.1. UČINAK NA ZADATKU ISTRAŽIVAČKOG UČENJA – STJECANJE ZNANJA O ODNOSIMA IZMEĐU NEZAVISNIH I ZAVISNE VARIJABLE U MODELU ZADATKA .....	117
5.1.1. <i>Usporedba početnih i završnih teorija učenika o učinku čimbenika na uništenje šuma</i> .....	117
5.1.2. <i>Promjene teorija učenika tijekom rada na zadatku</i> .....	121
5.1.3. <i>Promjene u točnosti predviđanja rezultata eksperimenata tijekom rada na zadatku</i> .....	124
5.1.4. <i>Učinak na zadatku istraživačkog učenja: integracija rezultata i rasprava</i> .....	127

5.2. JAČANJE ISTRAŽIVAČKIH VJEŠTINA I STRATEGIJA TIJEKOM RADA NA ZADATKU .....	129
5.2.1. Plan istraživanja za pojedini eksperiment (istraživačka namjera) .....	129
5.2.2. Postavljanje hipoteza .....	132
5.2.3. Eksperimentiranje .....	135
5.2.4. Donošenje zaključaka o učinku čimbenika na uništenje šume .....	144
5.2.5. Jačanje istraživačkih vještina i strategija tijekom rada na zadatku: integracija rezultata i rasprava.....	156
5.3. JAČANJE METAKOGNITIVNIH VJEŠTINA I POVEZANOST S ISTRAŽIVAČKIM VJEŠTINAMA I STRATEGIJAMA I UČINKOM NA ZADATKU .....	162
5.3.1. Planiranje i organiziranje rada na zadatku istraživačkog učenja .....	162
5.3.2. Korištenje funkcija programa FILE i vođenje bilježaka tijekom rada na zadatku.....	165
5.3.3. Metakognitivne vještine: integracija rezultata i rasprava .....	169
5.4. STIJEKANJE METAKOGNITIVNOG ZNANJA O CILJU I STRATEGIJAMA RADA NA ZADATKU I POVEZANOST S ISTRAŽIVAČKIM VJEŠTINAMA I STRATEGIJAMA I UČINKOM NA ZADATKU .....	173
5.4.1. Promjene u metakognitivnom znanju o cilju i strategijama rada na zadatku .....	173
5.4.2. Odnos metakognitivnog znanja učenika i istraživačkih vještina .....	182
5.4.3. Metakognitivno znanje o cilju i strategijama rada na zadatku: integracija rezultata i rasprava.....	188
5.5. ULOGA MOTIVACIJE I METAKOGNITIVNOG DOŽIVLJAJA ZADATKA U PROCESIMA I ISHODIMA ISTRAŽIVAČKOG UČENJA .....	196
5.5.1. Promjene motivacijskih, metakognitivnih i emocionalnih procjena tijekom rada na zadatku ..	196
5.5.2. Profiliranje učenika s obzirom na doživljaj zadatka istraživačkog učenja .....	202
5.5.3. Razlike između motivacijskih profila učenika u motivaciji i metakognitivnom doživljaju tijekom rada na zadatku .....	208
5.5.4. Razlike između motivacijskih profila učenika u procesima i ishodima istraživačkog učenja ....	210
5.5.5. Motivacija, metakognitivni doživljaj i istraživačko učenje: integracija rezultata i rasprava ....	212
<b>II. DIO: ANALIZA PROCESA ISTRAŽIVAČKOG UČENJA TIJEKOM RADA NA ZADATKU:</b>	
<b>KVALITATIVNA ANALIZA SLUČAJEVA .....</b>	<b>222</b>
5.6. ODABIR SLUČAJEVA ZA KVALITATIVNU ANALIZU .....	223
5.7. RAZVOJ KVALITATIVNOG ANALITIČKOG OKVIRA (KODNE SCHEME).....	224
5.8. REZULTATI KVALITATIVNE ANALIZE PROCESA ISTRAŽIVAČKOG UČENJA .....	227
5.8.1. Niska razina strateške izvedbe na zadatku (Lena i Oliver) .....	228
5.8.2. Značajan napredak u radu na zadatku (Marin i Dea) .....	246
5.8.3. Visoka razina strateške izvedbe na zadatku (Borna i Iva) .....	264
5.9. ZAKLJUČNA RAZMATRANJA O REZULTATIMA KVALITATIVNE ANALIZE PROCESA ISTRAŽIVAČKOG UČENJA.....	278
<b>POGLAVLJE 6. ZAKLJUČAK .....</b>	<b>290</b>
6.1. METODOLOŠKE IMPLIKACIJE I OGRANIČENJA ISTRAŽIVANJA .....	290
6.2. ODGOVORI NA ISTRAŽIVAČKA PITANJA .....	296
6.3. IMPLIKACIJE ZA BUDUĆA ISTRAŽIVANJA.....	305
6.4. IMPLIKACIJE ZA OBRAZOVNU PRAKSU .....	307
<b>LITERATURA .....</b>	<b>311</b>
<b>SAŽETAK I KLJUČNE RIJEČI.....</b>	<b>327</b>
<b>SUMMARY AND KEY WORDS .....</b>	<b>328</b>
<b>ŽIVOTOPIS.....</b>	<b>329</b>
<b>PRILOZI.....</b>	<b>330</b>

## ZAHVALA

Afrička poslovice kaže: „Potrebno je cijelo selo da se odgoji dijete“.

Želim zahvaliti svim dobrim ljudima koji su pomogli *odgojiti ovo moje dijete*:

Ani, Bruni, Dori, Dorotei, Dunji, Eni, Heleni, Ivani, Ivani, Jeleni, Josipu, Karlu, Kristini, Lauri, Lovri, Lucii, Luciji, Luki, Luki, Margiti, Marku, Marku, Marku, Mateju, Matiji, Mihaelu, Noi, Omeru, Petri, Petru, Romanu, Teni, Tini i Tomislavu za spremno sudjelovanje u istraživanju,

prof. dr. Vlasti Vizek Vidović, mojoj mentorici, za ukazano povjerenje, razumijevanje i korisne savjete pri provedbi istraživanja i izradi rada,

Borisu Jokiću za prijateljstvo, brigu, neumorne rasprave i drugarsku kritiku,

Petru Bezinoviću za bezuvjetnu podršku i bodrenje,

Krešimiru Joziću za velikodušan rad na izradi zadatka,

mr. sc. Višnji Reljić (ravnateljici OŠ Ivana Gundulića), Slavici Vukčević, prof. (ravnateljici OŠ Gustav Krklec), Željki Blažinović (logopedinji u OŠ Gustav Krklec) i Zdravku Furlanu, prof. (ravnatelju OŠ Otok) za gostoprimstvo i ljubaznost s kojom su me dočekali,

Martini Prpić, Marini Štibrić, Ivani Lovrić i Sanji Klarić za nesebičnu pomoć pri prikupljanju i unosu podataka

i svim kolegicama i kolegama iz Centra za istraživanje i razvoj obrazovanja i Instituta za društvena istraživanja za podršku i strpljenje.

## **POGLAVLJE 1. UVOD U ISTRAŽIVANJE**

---

### **1.1. Zašto istraživati istraživačko učenje?**

U zadnjih pedesetak godina dogodile su se dramatične promjene u konceptualizaciji znanosti, ali i konceptualizaciji učenja i metodike poučavanja znanosti (Grandy i Duschl, 2007). Kao posljedica tih promjena, u svim obrazovnim sustavima izrazito jača interes za istraživačkim učenjem kao obrazovnim pristupom koji stavlja učenike u poziciju provođenja „pravih“ istraživanja kakva prakticiraju znanstvenici kad stvaraju novo znanje (Kuhn, 2005). Istraživačko učenje se smatra superiornim pristupom nad tradicionalnim poučavanjem, jer učenike uvodi u aktivnosti koje od njih zahtijevaju provođenje svih faza istraživačkog rada i upravljanje istraživačkim procesima, pri čemu se, uz konstruiranje vlastitog razumijevanja svijeta, kod učenika razvijaju istraživačke vještine, ali i vještine samostalnog, samoreguliranog učenja, komunikacijske vještine, vještine rada u grupi itd. Vrijednost takvog pristupa očituje se i u tome što sudjelovanje u istraživačkim aktivnostima potiče prirodnu znatiželju, promovira znanstvenu aktivnost kao intelektualnu vrijednost i potkrepljuju gledanje na svijet i prirodne i društvene pojave kao na fenomene koji se mogu zahvatiti na istraživački način (Keselman i Kuhn, 2002). Osim toga, iako se istraživački pristup najčešće smatra dijelom prirodoznanstvenog obrazovanja, on je primjenjiv u različitim predmetnim područjima (i u svakodnevnom životu), i obrazovno je relevantan za sve učenike, a ne samo za manji dio onih koji žele nastaviti svoj profesionalni put u znanstvenim disciplinama (Kuhn, 2005; Zimmerman, C. 2005).

S obzirom na navedeno, ne iznenađuje što se istraživačko učenje pojavljuje kao obrazovni cilj u različitim zemljama (Abd-El-Khalick i sur., 2004; EURYDICE, 2006), te da se kvalitetno učenje i poučavanje u području prirodoslovlja često izjednačuje s korištenjem istraživačkog učenja (Anderson, 2002). Danas je gotovo nemoguće pronaći kurikulume za obvezno obrazovanje koji ne postavljaju sudjelovanje učenika u istraživačkim aktivnostima kao obrazovni cilj u prirodoznanstvenom području. U američkim nacionalnim standardima za znanost osmišljavanje i provedba istraživanja pojavljuju se kao obrazovni cilj u svim razredima od drugog do dvanaestog (National Research Council, 2000). I europski dokumenti snažno zagovaraju istraživačko učenje kao obrazovni cilj, te ističu da preokret s pretežito deduktivne metodike na induktivni, istraživački pristup omogućuje

učenicima korištenje i razvijanje šireg spektra vještina, povećava znatiželju i interes učenika za znanost, te dovodi do boljih obrazovnih postignuća (Rocard i sur., 2007). Osborne i Dillon (2008), ističući činjenicu da je prirodnoznanstveno obrazovanje važno za svu djecu, a ne samo za one koji će postati profesionalni znanstvenici, zaključuju da naglasak prirodnoznanstvenog obrazovanja u osnovnoškolskom obrazovanju treba biti upravo na osiguravanju prilika za kontinuirani istraživački rad i neposredno iskustvo s eksperimentiranjem, a ne na stjecanju kanona znanstvenih koncepata.

Istom trendu uključivanja istraživačkih aktivnosti u predmetne kurikulume pridružuje se i Republika Hrvatska, tako da Nastavni plan i program za osnovnu školu postulira izvođenje pokusa jednom od glavnih zadataka koja se mora ostvariti u prirodoslovnim predmetima (MZOS, 2006). Već u trećem razredu osnovne škole u predmetu Priroda i društvo uvodi se tema «Pokus», unutar koje je obrazovno postignuće *«izvoditi jednostavne pokuse i zaključke o pojavnim oblicima vode»* (str. 256). U sedmom i osmom razredu, kad se prirodoslovlje odvaja u predmete biologija, kemija i fizika, stavljen je veći naglasak na istraživačke aktivnosti. Primjerice, već se u uvodu u predmet kemija navodi da *«budući da je kemija tipična eksperimentalna znanost, iskustveno je učenje glavni način učenja, a izvođenje pokusa središnja nastavna aktivnost»* (str. 272), a zadaćama fizike se smatra *«da učenike treba...motivirati da postavljaju pitanja i tragaju za odgovorima, poučiti da osmisle, izvode i analiziraju jednostavne pokuse, postavljaju pretpostavke i stvaraju jednostavne slike o pojavama, ....poticati na logično i samostalno zaključivanje te u učenicima, pri proučavanju prirodnih pojava, razviti kritičko mišljenje i prosuđivanje.... te ih osposobiti za samostalno rješavanje problema, ali i za konstruktivnu suradnju pri timskome radu»* (str. 279).

I dok se vodeći obrazovni teoretičari uglavnom slažu u ocjeni važnosti istraživanja (engl. *inquiry*) za prirodnoznanstveno obrazovanje, nije prisutan potpuni konsenzus o tome što ono zapravo jest i što ono obuhvaća (Anderson, 2002; Abd-El-Khalick i sur., 2004; Grandy i Duschl, 2007). Istraživanje se može shvatiti i kao sredstvo (metoda učenja i poučavanja) i kao obrazovni cilj. Istraživanje kao sredstvo predstavlja pristup koji pomaže učenicima u razvoju razumijevanja sadržaja znanosti, dok istraživanje kao cilj podrazumijeva da učenici provode istraživanja u kontekstu znanstvenih sadržaja, pri čemu ne samo da stječu znanstveno znanje i relevantne istraživačke vještine, već i razvijaju epistemološko razumijevanje o prirodi znanosti. U današnje vrijeme ipak je dominantno stajalište koje kaže da je osnovni cilj obveznog znanstvenog obrazovanja i razvoj razumijevanja

znanstvenog znanja i toga kako znanost djeluje (kako se dolazi do znanja i koja su ograničenja znanstvenih spoznaja), pa se unutar prirodoslovnog obrazovanja uglavnom prihvaća dvojno shvaćanje istraživanja i kao sredstva i kao cilja.

No, usprkos širokoj podršci istraživačkom učenju u dokumentima obrazovne politike u različitim obrazovnim sustavima i prihvaćanju istraživačkog pristupa kao najučinkovitijeg pristupa obrazovanja u znanosti, realitet nastavne prakse govori da u većini europskih zemalja takav pristup nije zadovoljavajuće implementiran (Rocard i sur., 2007). Problem je prisutan i u drugim obrazovnim sustavima (npr. u Australiji, Izraelu, Tajvanu, SAD-u), gdje se također pokazuje da pristupi učenju i poučavanju koji se koriste u školama znatno odstupaju od vizija postavljenih u dokumentima obrazovne politike (Abd-El-Khalick i sur., 2004). Dominantni pristup u prirodoslovnom obrazovanju i dalje je preuzak, ograničen uglavnom na transmisiju znanja i orijentiran na sadržaje (Rocard i sur., 2007; Osborne i Dillon, 2008). Čak i eksperimenti koji se provode ne odražavaju ključne odrednice autentičnog znanstvenog istraživanja (Chinn i Malhorta, 2002), već služe uglavnom kao ilustracija nastavnikovih tvrdnji, ili se provode «po receptu», bez prave mogućnosti učenika da preuzmu aktivnu ulogu u konstrukciji vlastitog znanja i koriste više kognitivne procese<sup>1</sup>.

Razlozi takvog stanja vrlo su različiti. Prepreke široj implementaciji istraživačkog pristupa mogu se pronaći u slaboj opremljenosti škola, organizacijskim problemima, neprikladnom obrazovanju nastavnika i dominantnoj kulturi poučavanja znanosti u školama (Anderson, 2002; Abd-El-Khalick i sur., 2004). Međutim, nedovoljno korištenje istraživačkog pristupa u školama može se povezati i s nedostatnim znanstvenim spoznajama o prirodi i razvoju znanstvenog razmišljanja i istraživačkog učenja kod učenika u osnovnoškolskoj i srednjoškolskoj dobi. Premalo je istraživanja o tome koja znanja i vještine se razvijaju, i koja znanja i vještine treba razviti kod učenika u području znanstvenog razmišljanja (Kuhn, 2005). Te su spoznaje ključne kao osnova za razvoj kvalitetnih i učinkovitih obrazovnih praksi za poticanje istraživačkih kompetencija.

---

<sup>1</sup> Hrvatska ovdje nije izuzetak, međutim, nedostaju relevantna istraživanja koja bi potkrijepila to stajalište. U okviru istraživanja prikazanog u ovom radu prikupljeni su podaci o stavovima i preferencijama učenika dvije zagrebačke osnovne škole o korištenju eksperimenata u nastavi fizike, kemije i biologije. Premda se ti podaci, zbog nereprezentativnosti uzorka škola, mogu smatrati više anegdotalnim, nego znanstveno relevantnim, zanimljiv je podatak da, iako se na nastavi prirodoslovnih predmeta eksperimentira relativno često (više puta mjesečno na fizici i kemiji), oko 95% učenika smatra da nikad ili rijetko samostalno osmišljavaju pokuse te da samostalno izvode pokuse, bez detaljnih uputa nastavnika. Pokusi se gotovo uvijek provode tako da učenici gledaju demonstracijske pokuse nastavnika ili tako da u malim grupama učenici slijede upute i korake koje zadaje nastavnik.

Razvojna psihologija zasad nije pružila jednoznačne nalaze o razvoju istraživačkih vještina, budući da istraživanja, s jedne strane, ukazuju na ranu kompetentnost u području kauzalnog zaključivanja, a, s druge strane, na nedostatnu razvijenost kauzalnog i znanstvenog razmišljanja čak i u odrasloj dobi (Zimmerman, 2007; Kuhn, 2009). Nedvojbeno se, međutim, pokazuje da u situacijama koje od učenika zahtijevaju samoupravljanje ili djelomično upravljano eksperimentiranje, učenici doživljuju probleme u različitim fazama istraživačkog procesa (Zimmerman, C. 2001, 2005, 2007). Smatra se da učenici imaju nedostatne kognitivne i metakognitivne vještine potrebne za učinkovito istraživačko učenje, kao i da se vještine uključene u istraživačko učenje i znanstveno razmišljanje ne razvijaju same od sebe, bez prikladnog obrazovnog iskustva, kao nastavak prirodne znatiželje koja se opaža već kod male djece (Kuhn, 2005). I dok se najprikladnijim obrazovnim iskustvom pokazuje upravo neposredno sudjelovanje učenika u istraživačkim aktivnostima koja, barem u temeljnim crtama, odgovaraju autentičnim istraživanjima kakva se provode u znanosti, nije opravdano pretpostaviti da učenici već posjeduju vještine potrebne za rad na takvim zadacima. Prije uključivanja u zadatke istraživačkog učenja, čini se nužnim podučiti učenike određenim vještinama potrebnima za samoupravljanje eksperimentiranje (Keselman i Kuhn, 2002) i prilagoditi zahtjeve zadataka njihovim razvojnim kapacitetima (Kuhn i Pease, 2008).

Iako su u literaturi dostupni nalazi brojnih istraživanja o razvojnim kapacitetima učenika u pojedinim aspektima znanstvenog razmišljanja (za pregled vidjeti Zimmerman, C. 2001, 2005, 2007), za uspješnu primjenu istraživačkog pristupa u obrazovanju potrebno je mnogo više znanja o tome kako učenici rade na zadacima istraživačkog učenja (bilo uz minimalnu potporu ili u uvjetima vježbe i treninga), koje kognitivne i metakognitivne vještine i strategije<sup>2</sup> oni koriste u istraživačkom radu, kakvo je njihovo subjektivno iskustvo koje prati istraživačku aktivnost, i kako se kroz proces učenja razvijaju učenikove istraživačke vještine, njihovo razumijevanje znanstvenih koncepata, razumijevanje prirode znanosti, motivacija za istraživačko učenje i područje znanosti općenito. Nedovoljna istraženost ovih relevantnih pitanja motivirala je, dakako, provođenje istraživanja predstavljenog u ovome radu.

---

<sup>2</sup> Razlikovanje pojmova 'strategija' i 'vještina' nije posve precizno. Strategija je neobavezna, ali cilju usmjerena aktivnost (Siegler i Jenkins, 1989) Uz strategije se, u odnosu na vještine, veže veći stupanj osvještenog korištenja i namjere, a manji stupanj automatiziranosti. I strategije i vještine označavaju skup organiziranih procesa ili pravila koji se koriste kako bi se ostvario neki cilj.

Međutim, istraživački interes za bavljenje područjem znanstvenog razmišljanja i istraživačkog učenja dodatno je pojačan činjenicom da u Hrvatskoj nema sustavnih obrazovnih i/ili psihologijskih istraživanja znanstvenog razmišljanja. Iznimku predstavlja sudjelovanje Republike Hrvatske u OECD-ovom međunarodnom istraživačkom programu PISA 2006 koji je bio posvećen ispitivanju razvijenosti prirodoslovne pismenosti kod petnaestogodišnjaka. Uz ispitivanje prirodoslovnih znanja i stavova prema prirodoslovlju, ispitivane su prirodoslovne kompetencije učenika, odnosno njihova sposobnost identificiranja znanstvenih pitanja, znanstvenog objašnjavanja pojava i korištenja znanstvenih nalaza (OECD, 2006). Rezultati tog istraživanja pokazuju da se hrvatski petnaestogodišnjaci nalaze po prosječnom rezultatu iz prirodoslovne pismenosti ispod razine prosjeka OECD zemalja, te da 17% učenika ne zadovoljava razinu 2 (od ukupno 6) koja se smatra minimalnom razinom potrebnom za učinkovitu primjenu prirodoslovnih znanja (Braš Roth, Gregurović, Markočić Dekanić i Markuš, 2008).

Ovi relativno nepovoljni rezultati hrvatskih učenika potiču na razmišljanje i dublje istraživanje razvijenosti znanstvenog razmišljanja u našem obrazovnom kontekstu. Istraživanje, predstavljeno u ovom radu, predstavlja jedan takav pokušaj.

## **1.2. Zašto u istraživanju istraživačkog učenja koristiti okvir samoregulirajućeg učenja?**

U današnje vrijeme, najviše mjesto u hijerarhiji obrazovnih ciljeva u bilo kojem obrazovnom sustavu ili obrazovnom programu vjerojatno zauzima zahtjev za osposobljavanjem učenika za samostalno upravljanje i reguliranje vlastitih procesa učenja. U Europskom okviru ključnih kompetencija, «učiti kako učiti», koncept blizak samoregulirajućem učenju, pojavljuje se kao jedna od osam ključnih kompetencija u obrazovanju (Education Council, 2006). Zbog svoje središnje uloge u određivanju kvalitete učenja i postignuća učenika u školi i izvan nje, samoregulirajuće učenje je postalo jedan od ključnih konstrukata u obrazovanju (Boekaerts i Cascallar, 2006).

Jasan je stoga interes za istraživanjem u ovom području. Potrebno je, međutim, ponešto pojasniti zašto je okvir samoregulirajućeg učenja korišten za istraživanje istraživačkog učenja.

Iako će koncepti samoregulirajućeg učenja i istraživačkog učenja biti detaljno objašnjeni u narednom poglavlju koje daje pregled literature iz oba područja, već je uvodno važno



odrediti da se pod samoregulirajućim učenjem podrazumijeva višekomponentni, ciklički, samoinicirani *proces* koji zahvaća kognitivne, metakognitivne i motivacijske sustave, ponašanje i prilagođavanje situacija učenja, u cilju ostvarivanja učeničkih ciljeva (Boekaerts i Cascallar, 2006). Ovakvo određenje samoregulirajućeg učenja zajedničko je različitim teorijskim konceptualizacijama ovog pojma, kao i shvaćanje o samoregulirajućem učenju kao konstrukt koji omogućuje istraživačima opisivanje različitim aspektata uspješnog učenja, objašnjenje recipročnih veza koje se događaju među različitim sastavnicama procesa učenja i povezivanje učenja i postignuća sa samopoimanjem, motivacijom i emocijama učenika (Boekaerts, 1999).

Razumijevanje samoregulirajućeg učenja kao složenog procesa koji uključuje kognitivne, metakognitivne, motivacijske i emocionalne aspekte koji se dinamično mijenjaju i razvijaju u kontekstu pojedinih, specifičnih epizoda učenja čini ga pogodnim okvirom za istraživanje istraživačkog učenja. U zadatku istraživačkog učenja, kakav je korišten u i ovome istraživanju, učenici individualno istražuju jedan relativno jednostavan računalno prikazani multivarijantni kauzalni model s ciljem razumijevanja odnosa između nezavisnih i zavisne varijable. U tom zadatku, učenici provode sve faze istraživačkog ciklusa (od formuliranja pitanja i postavljanja hipoteza, preko eksperimentiranja mijenjanjem razina nezavisnih varijabli, do vrednovanja nalaza i kauzalnog zaključivanja na temelju opažanja promjena u zavisnoj varijabli) te samostalno upravljaju vlastitim istraživačkim procesom. Iako je situacija učenja jasno strukturirana unutar računalnog okruženja zadatka i konteksta istraživanja, rad učenika na zadatku nije pod neposrednom kontrolom istraživača, pa je izrazito ovisan o samim učenicima, odnosno o tome što oni misle i čine u procesu učenja. Zadatak od učenika zahtijeva aktivno i samoregulirano učenje, budući da učenik uči o multivarijantnom kauzalnom modelu kroz aktivnosti koje sam započinje, provodi i kontrolira. Učenik sam odlučuje o tijeku i završetku procesa učenja. Zadatak je relativno složen, pa zahtijeva od učenika izbor i primjenu različitih istraživačkih vještina, ali i korištenje metakognitivnih procesa praćenja i regulacije, te postojanje motivacijske spremnosti za ulaganje truda i održavanje ustrajnosti.

Dosadašnja istraživanja u području istraživačkog učenja, iako su načelno priznavala kompleksnost i samoregulirajuću prirodu istraživačkog učenja, uglavnom su se usmjeravala na ispitivanje (pojedinih) kognitivnih i metakognitivnih vještina uključenih u istraživački proces, a zanemarivala su subjektivna metakognitivna, motivacijska i emocionalna iskustva rada na takvim zadacima. Istraživanja o recipročnim i interaktivnim

vezama motivacije, metakognicije i samoregulacije učenja, odnosno istraživanja o tome kako učenici prate, kontroliraju i reguliraju svoju motivaciju i kognicije kad uče ili rješavanju neki problem ne nedostaju samo u području istraživanja istraživačkog učenja, nego i samoregulirajućeg učenja općenito (Pintrich, 1999, 2003).

Uz navedeno, dosadašnja istraživanja istraživačkog učenja često su cjeloviti istraživački proces segmentirala na pojedine faze, kako bi lakše identificirala i zahvatila određene procese. Tek se u novije vrijeme u području istraživanja znanstvenog razmišljanja razvija integrativni pristup koji pod istraživačkim učenjem podrazumijeva složeni proces koji zahtijeva koordinaciju različitih kognitivnih, metakognitivnih i metastrateških procesa, te uključuje međudjelovanje konceptualnog razumijevanja (znanja specifičnog za određeno područje, predmet istraživanja) i nespecifičnih (od područja neovisnih) istraživačkih vještina.

Pozicionirajući se unutar integrativnog pristupa, istraživanje prikazano u ovome radu nastoji odgovoriti na dosad neodgovorena pitanja o međuodnosima kognitivnih, metakognitivnih i motivacijskih sastavnica samoregulirajućeg istraživačkog učenja i razvoju tih procesa kroz epizode učenja koje od učenika traže primjenu istraživačkih vještina. Uz to, istraživanje nastoji unaprijediti spoznaje o povezanosti motivacijskih, metakognitivnih i kognitivnih procesa i ishoda istraživačkog učenja i time omogućiti bolje razumijevanje uloge samoregulacije u istraživačkom učenju.

Kako bi se to ostvarilo, u istraživanju je sustavno i detaljno praćen rad manjeg uzorka učenika na jednom zadatku istraživačkog učenja u nekoliko situacija učenja. Iako će metodologija istraživanja biti obrađena u posebnom poglavlju ovog rada, u nastavku je dat kratak uvod u odabrani metodološki pristup.

### **1.3. Metodološki pristup istraživanju**

Istraživanje prikazano u ovome radu polazi od dvije osnovne ideje:

1. Samoregulirajuće učenje je proces koji se odvija u realnom vremenu, u specifičnim situacijama učenja.
2. Istraživačko učenje je kompleksno učenje u koje su uključeni mnogi procesi. Razumijevanje procesa i ishoda istraživačkog učenja je nepotpuno bez poznavanja toga kako u specifičnim situacijama učenja međusobno djeluju, mijenjaju se i razvijaju pojedini kognitivni, metakognitivni i motivacijski procesi.

Ovakvim postavkama prikazano se istraživanje priključuje korpusu istraživanja koja samoregulirajuće učenje promatraju kao događaj (Winne, Jamieson-Noel i Muis, 2002; Winne i Perry, 2005), odnosno kao kontekstualiziran, dinamičan i složen proces (npr. Ainley i Patrick, 2006; Boekaerts i Cascallar, 2006; Perry i Winne, 2006).

Kako bi se zahvatili različiti procesi koji djeluju u procesu samoregulacije istraživačkog učenja, kao i njihovi međusobni odnosi, istraživanje se usmjerava na mikrorazinu iskustva rada na jednog zadatku istraživačkog učenja. Taj zadatak predstavlja okvir unutar kojeg se ispituju različiti procesi i mehanizmi, koji su ograničeni upravo tom specifičnom situacijom u kojoj se odvija istraživačko učenje. Ispituju se integrirane epizode učenja, onako kako se one odvijaju u vremenu, a sve su varijable operacionalizirane na istoj razini mjerenja – kao situacijski specifični procesi i procjene vezane uz taj konkretan zadatak.

Orijentiranost na proces i na to kako specifični motivacijski, metakognitivni i kognitivni procesi djeluju na učenje uvjetuju da se ti procesi mjere tijekom rada na zadatku simultano i direktno, u slijedu u kojem se događaju. Prati se i bilježi to što učenici rade kad pokušavaju riješiti zadatak, pa je moguće utvrditi dinamičke odnose i sekvencijalne kontigencije između pojedinih procesa. Kombiniraju se podaci iz različitih izvora – iz strukturiranih upitnika, verbalnih («misli naglas») protokola, polustrukturiranih intervjua, opažanja i praćenja tragova procesa učenja putem automatskog računalnog zapisnika. Iste mjere se ponavljaju tijekom rada unutar pojedine situacije učenja, što omogućuje dobivanje uvida u fluktuacije ili promjene pojedinih procesa koje se mogu dogoditi kako učenik napreduje kroz zadatak.

Osim praćenja subjektivnog iskustva učenika tijekom rada na zadatku, neposredno prije i poslije pojedinih epizoda učenja ispituje se motivacija i metakognitivni doživljaj učenika, kako bi se zahvatila neposredna očekivanja i reakcije učenika na vlastiti rad.

U istraživanju učenici sudjeluju u četiri vremenski odvojene epizode učenja, ali rade na istom zadatku istraživačkog učenja. Takav istraživački pristup, u kojem se učenici ponavljano, u relativno kratkim vremenskim razdobljima, izlažu situacijama učenja kako bi se istraživali procesi promjena u znanju, vještinama i razumijevanju, u literaturi se naziva mikrorazvojnim (Granott i Parziale, 2002) ili mikrogenetskim istraživačkim dizajnom (Siegler i Crowley 1991; Kuhn, 1995; Chen i Siegler, 2000; Lavelli, Pantoja, Hsu, Messinger i Fogel, 2005; Siegler, 2006; Flynn i Siegler, 2007; Flynn, Pine i Lewis, 2006, 2007).

Mikrorazvojni istraživački pristup, zbog blizine i intenziteta mjerenja pojedinih epizoda učenja, te zbog bogatstva prikupljenih podataka, osigurava pristup trenutnim procesima učenja i praćenje toga kako učenici konstruiraju novo znanje i razvijaju istraživačke vještine i strategije. Također, zbog detaljnosti podataka o subjektivnom iskustvu i ponašanjima pojedinih ispitanika tijekom rada na zadatku, pristup omogućuje ispitivanje intraindividualnih i interindividualnih razlika u procesima učenja.

## **POGLAVLJE 2. PREGLED REZULTATA ISTRAŽIVANJA U PODRUČJU (SAMOREGULIRAJUĆEG) ISTRAŽIVAČKOG UČENJA**

---

Ovo se poglavlje sastoji od dva osnovna dijela. U prvom dijelu prikazano je područje istraživanja znanstvenog razmišljanja. Predstavljen je koncept 'znanstvenog razmišljanja' koji se preuzima u ovom istraživanju, te su u kratkim crtama prikazana dva glavna pristupa istraživanjima znanstvenog razmišljanja: pristup usmjeren na (produkte) sadržaje znanstvenog razmišljanja i pristup usmjeren na procese - istraživačke vještine i strategije. Poseban je naglasak u ovom dijelu pregleda literature stavljen na teorijska razmatranja i rezultate istraživanja u okviru integrativnog pristupa istraživanjima znanstvenog razmišljanja. Integrativni pristup, koji je zauzet i u ovome istraživanju, počiva na zadacima samoupravljanog istraživačkog učenja, u kojima učenici sudjeluju u svim fazama istraživačkog procesa - od postavljanja istraživačkih pitanja i hipoteza, preko eksperimentiranja, do kauzalnog zaključivanja i revidiranja početnih teorija i hipoteza. U pregledu su predstavljeni tipični obrasci djelovanja, te najčešći problemi s kojima se učenici<sup>3</sup> susreću u pojedinim fazama istraživačkog procesa.

U drugom dijelu poglavlja, istraživačko učenje je stavljeno u širi kontekst samoregulirajućeg učenja. Znatan dio ovog podpoglavlja posvećen je objašnjenju zajedničkih ideja koje proizlaze iz različitih teorijskih konceptualizacija samoregulirajućeg učenja, te opisu metakognitivnih i motivacijskih sastavnica tog procesa. U pregledu su prikazani rezultati istraživanja o ulozi metakognicije i motivacije u procesima i ishodima istraživačkog učenja, u opsegu u kojem su podaci o takvim istraživanjima bili u literaturi prisutni. Na kraju, dat je prikaz razvoja metodologije mjerenja samoregulirajućeg učenja, od prvih istraživanja koja su samoregulirajuće učenje pokušavala zahvatiti upitničkim mjerama poput stabilnih sklonosti reagiranja u različitim situacijama učenja, do danas kad se pronalaze prikladniji načini mjerenja samoregulirajućeg učenja kao kompleksnog, dinamičkog i kontekstualiziranog procesa.

---

<sup>3</sup> Termin „učenik“ se ne odnosi nužno na školsku djecu, već se koristi u širem smislu, te obilježava ispitanike koje sudjeluju u zadacima istraživačkog učenja.

# I. DIO: PREGLED PODRUČJA ISTRAŽIVANJA ZNANSTVENOG RAZMIŠLJANJA I ISTRAŽIVAČKOG UČENJA

## 2.1. Što je znanstveno razmišljanje?

Definirajući znanstveno razmišljanje (engl. *scientific reasoning, scientific thinking, scientific discovery*), Klahr (2000) iznosi da je znanstveno razmišljanje skup kognitivnih procesa uključenih u rješavanje problema, koji su ograničeni jedinstvenim karakteristikama znanstvenih problema. Znanstveno razmišljanje se promatra kao složena aktivnost rješavanja problema koja koristi iste mehanizme procesiranja informacija koji su prisutni u drugim situacijama rješavanja problema, samo na znanstvenim sadržajima (Klahr i Dunbar, 1988; Klahr, 2000). Radi se o rješavanju problema, koje je usmjerena potraga i proces prikupljanja podataka, s ciljem stjecanja znanja u obliku hipoteza ili teorija koje mogu služiti kao generalizacije i objašnjenja skupova podataka na koncizan način ili u općoj formi (Klahr, 2000).

Naslanjajući se na Klahrovu definiciju znanstvenog razmišljanja kao rješavanja znanstvenih problema, Dunbar i Fugelsang (2005) navode da se znanstveno razmišljanje odnosi na mentalne procese koji se koriste kad se rezonira o sadržajima iz područja znanosti i sudjeluje u tipičnih znanstvenim aktivnostima. Ova definicija, koja pod znanstvenim razmišljanjem podrazumijeva specifične procese rezoniranja koji se koriste u znanosti, međutim, ne otkriva mnogo o tome o kojim i kakvim se procesima i aktivnostima zapravo radi. U tom smislu više pomaže definicija koju daje Zimmerman, C. (2005), koja navodi da znanstveno razmišljanje uključuje različite vještine mišljenja uključene u otkrivanje, eksperimentiranje, vrednovanje nalaza, donošenje zaključaka i argumentiranje u svrhu znanstvenog razumijevanja i konceptualne promjene, odnosno stvaranja i mijenjanja koncepata i teorija o prirodnom i socijalnom svijetu.

Nadovezujući se na definicije znanstvenog razmišljanja kao primjene metoda i principa znanstvenog istraživanja u situacijama rješavanja problema, ista autorica 2007. godine ističe da je, uz vještine potrebne za stvaranje, testiranje i revidiranje teorija, za potpunu kompetentnost u znanstvenom razmišljanju ključna refleksija na proces stjecanja znanja i promjena u znanju (Zimmerman, 2007).

Kuhn (2002a) zauzima ponešto širu definiciju znanstvenog razmišljanja od onih koje ograničavaju znanstveno razmišljanje na specifične procese rezoniranja i na «ono što čine znanstvenici». Autorica se zalaže za shvaćanje znanstvenog razmišljanja kao ljudske aktivnosti koja je relevantna ne samo u znanosti, nego i izvan nje, te koja je često socijalna po svojoj prirodi (Kuhn, 2002a). Znanstveno razmišljanje definira kao intencionalni proces traženja znanja, koji može dovesti do znanstvenog razumijevanja ukoliko se odvija u povoljnim uvjetima (Kuhn, 1989). Pod procesom traženja znanja autorica podrazumijeva složeni proces koordiniranja teorija koje učenici imaju o svijetu oko sebe i sebi samima i nalaza do kojih učenici dolaze u procesu traženja znanja. Podrazumijeva se da djeca od svoje najranije dobi konstruiraju teorije o tome kako funkcionira svijet, budući da imaju potrebu osmisliti i organizirati svoje iskustvo. Te su teorije često netočne, fragmentirane i implicitne. U dodiru s novim informacijama koje se mogu povezati s teorijama koje djeca imaju, njihove se teorije mogu revidirati u procesu konceptualne promjene. Proces revidiranja teorija uvijek uključuje koordinaciju teorija i nalaza, a vodi boljem razumijevanju svijeta oko sebe. Međutim, prilagodba ili mijenjanje teorija u ranoj dobi većinom se događa nesvjesno, bez namjere i ulaganja truda. Za razliku od toga, ključni element znanstvenog razmišljanja je upravo diferenciranje i koordiniranje teorija i nalaza na svjestan, namjeran i eksplicitan način (Kuhn i Pearsall, 2000; Kuhn, 2002a, 2002b; Kuhn i Franklin, 2006). Naglašavajući da je koordinacija teorija i nalaza na svjestan i kontroliran način osnova zrelog znanstvenog razmišljanja, autorica veliku važnost daje metakognitivnim procesima praćenja, kontrole i regulacije u istraživačkom procesu (Kuhn, 2000, 2002b), pa navodi da je razumijevanje na meta razini ključan dio toga što se treba razviti u znanstvenom razmišljanju (Kuhn, 2002a; Kuhn, Katz i Dean, 2004). U tome razvoju, važnu ulogu autorica dodjeljuje i razvoju epistemološkog razumijevanja – razumijevanju procesa dolaženja do znanja, izvora znanja i kriterija za njegovo vrednovanje, koje je osnova pozitivnog vrednovanja znanja i intelektualnih vrijednosti ključnih za odvijanje procesa traženja znanja (Kuhn, 1997, 2001a; Kuhn i Pearsall, 2000; Kuhn i Dean, 2004b).

Složeni proces koordinacije teorija i nalaza kao temelja znanstvenog razmišljanja podrazumijeva da su za znanstveno razmišljanje važni i procesi (vještine potrage za znanjem/ istraživačke vještine) i produkti (konceptualno razumijevanje) znanstvenog razmišljanja, koji su međusobno povezani i međuzavisni (Zimmerman, C. 2000, 2005, 2007). Brojne su proceduralne i konceptualne sastavnice uključene u proces znanstvenog

razmišljanja (Zimmerman, C. 2000, 2005, 2007): postavljanje istraživačkih pitanja, formuliranje hipoteza, dizajniranje eksperimenata, korištenje pribora i pomagala, opažanje, mjerenje, predviđanje, provjeravanje, vođenje računa o točnosti, preciznosti i pogreškama, bilježenje i interpretiranje podataka, praćenje bilježaka, provođenje statističkih izračuna, vrednovanje nalaza, koordiniranje teorija i nalaza, zaključivanje, formuliranje i revidiranje teorija, prezentiranje i vrednovanje argumenata itd. Iz svega navedenog, jasno je da je znanstveno razmišljanje izuzetno kompleksna aktivnost koja zahtijeva koordinaciju mnogih kognitivnih vještina i strategija, te aktivaciju metakognitivnih i metastrateških procesa. Razumijevanje procesa znanstvenog razmišljanja je nepotpuno bez poznavanja toga kako interaktivno djeluju te kognitivne komponente s metakognitivnim i metastrateškim procesima (Zimmerman, C. 2005, 2007).

## **2.2. Glavni pristupi istraživanjima znanstvenog razmišljanja**

Iako su dva elementa znanstvenog razmišljanja (proces i produkti) međusobno povezani i teško odvojivi u situacijama kad učenici rade na zadacima koji zahtijevaju znanstveno razmišljanje, u prošlosti izučavanja znanstvenog razmišljanja jasno su se razlikovala dva pristupa: jedan koji se usmjeravao na *produkte* znanstvenog razmišljanja, odnosno na razvoj konceptualnog znanja u određenim znanstvenim područjima, i drugi, koji se usmjeravao na *proces* znanstvenog razmišljanja, odnosno na vještine potrebne za formuliranje hipoteza, eksperimentiranje, vrednovanje nalaza i donošenje zaključaka (Zimmerman, C. 2000, 2005). Kao posljedica te različite orijentacije, prvi se pristup uglavnom bavio znanjima vezanima uz pojedino znanstveno područje, a drugi istraživačkim vještinama i strategijama neovisnima o području.

Slično razlikovanje pristupa orijentiranih na procese i produkte znanstvenog razmišljanja čine i Lehrer i Schauble (2006) koji, govoreći o različitim slikama znanosti, opisuju pristup znanosti – kao - logičkog rezoniranja i znanosti – kao - teorije. Uz ta dva suprotstavljena pristupa, autori navode i treći pristup koji znanost promatra kao složenu aktivnost sudjelovanje u znanstvenoj praksi, koja se opire jednostavnim kategorizacijama.

*Pristup usmjeren na produkte*, odnosno pristup znanosti – kao - teorije, istražuje koncepte koje djeca i odrasli imaju o različitim pojavama iz pojedinih područja znanosti i usmjerava se na razvoj tih koncepata, znanstveno razumijevanje pojava, kao i na konceptualnu promjenu. Ispituju se naivni mentalni modeli i moguće pogrešne koncepcije, kao i



mogućnosti njihovog mijenjanja s iskustvom ili poučavanjem. U razmatranju toga kako se stječe znanje i razvija konceptualno razumijevanje, polazi se od toga da novi koncepti ulaze u područje, a postojeći koncepti počinju mijenjati značenje, ukoliko se teorijske strukture unutar kojih su koncepti smješteni značajno mijenjaju. Tako se rekonfigurira cijela mreža koncepata i njihovih odnosa (Lehrer i Schauble, 2006). Istraživači koji djeluju unutar ovog pristupa smatraju da nije opravdano zaključivati da djeca razmišljaju nelogično, već se radi o tome da se djeca oslanjaju na konceptualno razumijevanje svijeta koje trenutno imaju, a koje je manjkavo i različito od konceptualnog razumijevanja odraslih. Razvojne promjene se stoga ne odnose na svladavanje procesa mišljenja ili usvajanje novih oblika logičkog ili apstraktnog mišljenja, već na promjene u strukturama znanja (Lehrer i Schauble, 2006).

Unutar pristupa umjerenog na produkte znanstvenog razmišljanja, zadaci koji se u istraživanjima postavljaju takvi su da od ispitanika uobičajeno traže razmišljanje o nekom problemu, odgovaranje na pitanja ili rješavanje problema u skladu s vlastitim shvaćanjima koncepata koji se ispituju. Zadaci uglavnom ne traže od ispitanika provedbu eksperimenata, niti ne zahtijevaju opažanje ili vrednovanje podataka prikupljenih eksperimentima.

Istraživačke vještine i strategije se ispituju u sklopu *pristupa usmjerenog na procese znanstvenog razmišljanja*, koji se ne vezuje uz određena područja znanja, već naglašava ulogu znanstvenog rezoniranja neovisnog o području. Tu se pod znanstvenim razmišljanjem podrazumijeva primjena metoda ili principa znanstvenog istraživanja u problemnim situacijama (Kosłowski, 1996). Zbog složenosti procesa uključenih u znanstveno razmišljanje, u istraživanjima unutar ovog pristupa pojava se pokušava razložiti na dijelove, koji se onda ispituju u izolaciji od drugih dijelova (npr. formuliranje hipoteza, eksperimentiranje, vrednovanje nalaza). Također, u istraživanjima se uglavnom koriste zadaci koji se ne oslanjaju mnogo na prethodno znanje koje učenik ima u području, jer se na taj način lakše izoliraju opće vještine uključene u znanstveno razmišljanje i uklonila uloga znanja specifičnih za pojedino područje.

Tek u novijem razdoblju, imajući na umu da znanost karakteriziraju i produkti i procesi, pokušava se u istraživanjima otkriti veze konceptualnog znanja i strategija stvaranja hipoteza, eksperimentiranja, i zaključivanja (npr. Klahr i Dunbar, 1988; Kuhn, Garcia-Mila, Zohar i Anderson, 1995; Schauble, 1996). Ta istraživanja koja objedinjuju pristup usmjeren na proučavanje strategija neovisnih o području i pristup usmjeren na znanja

specifična za pojedino područje predstavljaju *integrativni pristup znanstvenom razmišljanju* (Klahr, 2000; Zimmerman, C. 2000, 2005, 2007). Unutar toga pristupa, istraživanja se većinom usmjeruju na znanstveno razmišljanje uključeno u otkrivanje i modifikaciju teorija o kategorijalnim kauzalnim odnosima (Zimmerman, C. 2000, 2005), a učenici aktivno sudjeluju u svim fazama istraživačkog procesa, tako da istraživač može pratiti i razvoj konceptualnog znanja i razvoj istraživačkih vještina i strategija. Cilj je ispitati recipročne odnose strategija na znanje i znanja na strategije u područjima u kojima učenici imaju neka početna znanja ili koncepcije, pa se zadaci postavljaju tako da ispitanici sudjeluju u djelomično vođenom ili samostalno vođenom eksperimentiranju, kako bi potvrdili, proširili ili promijenili svoje početne teorije. Uobičajeno se koriste simulacijski ili stvarni zadaci u srednje složenim područjima (Zimmerman, 2000).

Integrativni pristup proučavanju znanstvenog razmišljanja također često uključuje istraživanja koja opisuju i uspoređuju odnose znanja i procesnih vještina kod djece, odraslih i znanstvenika (Klahr i Simon, 1999).

### **2.2.1. Taksonomija istraživanja znanstvenog razmišljanja**

Klahr (2000) razrađuje taksonomiju istraživanja znanstvenog razmišljanja na temelju modela kognitivnih procesa uključenih u znanstvene aktivnosti, koji je pod nazivom «model znanstvenog otkrića kao dualne potrage» razvio sa suradnicima (engl. *Scientific Discovery as Dual Search Model* - Klahr i Dunbar, 1988; Klahr, 2000; Klahr i Simon, 2001; Li i Klahr, 2006). Model integrira elemente pristupa usmjerenog na produkte i pristupa usmjerenog na procese znanstvenog razmišljanja, odnosno povezuje znanja specifična za područje sa strategijama neovisnima o području, pa predstavlja prikladan okvir za sintetiziranje različitih istraživanja u području istraživanja znanstvenog razmišljanja (Zimmerman, C. 2000, 2005).

Prema tom SDDS modelu, koji ovdje neće biti detaljno opisan, znanstveno razmišljanje se promatra kao rješavanje problema koje uključuje potragu u prostoru problema. Znanstveno otkriće se postiže kroz proces dualne potrage koja se odvija u dva prostora problema – u prostoru hipoteza i prostoru eksperimenata. U procesu potrage, prostori hipoteza i eksperimenata su međusobno povezani i koordinirani, budući da prijašnja znanja i dostupni eksperimentalni rezultati vode potragu u prostoru hipoteza, a da postojeće hipoteze vode potragu u prostoru eksperimenata, s obzirom da se hipoteze mogu testirati ili generirati kroz vrednovanje eksperimenata. Proces potrage koji dovodi do znanstvenog otkrića

provodi se tako kroz tri osnovna procesa – potragu u prostoru hipoteza, potragu u prostoru eksperimenata i vrednovanje nalaza.

Klahr (2000) navodi da se pojedina istraživanja znanstvenog razmišljanja mogu kategorizirati s obzirom na dvije dimenzije. Jednu dimenziju čine glavni elementi SDDS modela – generiranje hipoteza, eksperimentiranje i vrednovanje nalaza, dok druga dimenzija razlikuje znanja specifična za određeno područje i znanja neovisna o području.

U tablici 1 prikazana je navedena taksonomija, unutar koje se mogu smjestiti različita istraživanja provedena u području istraživanja znanstvenog razmišljanja. Za pojedine ćelije i neke njihove kombinacije Klahr (2000) doista i pronalazi primjere konkretnih istraživanja iz literature.

*Tablica 1*  
Klahrova taksonomija psihologijskih istraživanja znanstvenog razmišljanja (Klahr, 2000)

	Generiranje hipoteza	Eksperimentiranje	Vrednovanje nalaza
Znanja specifična za područje	A	B	C
Znanja neovisna o području	D	E	F

Već spomenuta dva pristupa, onaj koji je orijentiran na produkte i onaj koji je usmjeren na procese znanstvenog razmišljanja, razlikuju se po tome na koju vrstu znanja stavljaju naglasak u istraživanjima. Pristup orijentiran na produkte znanstvenog razmišljanja, u sklopu kojega su dominantna ispitivanja konceptualnog razumijevanja i naivnih teorija učenika o određenim pojavama, usmjeren je ponajviše na ćeliju A (npr. McCloskey, 1983; prema Klahr, 2000). U tim istraživanjima učenike se ispituje o njihovim znanjima u određenom području, ali oni ne provode eksperimente, niti su im prikazani neki eksperimentalni nalazi koje bi mogli vrednovati.

Pristup orijentiran na procese znanstvenog razmišljanja više je vezan uz ćelije koje predstavljaju znanje neovisno o području (D, E, F). Tipična istraživanja ove vrste istražuju logiku eksperimentiranja i otkrivanja pravila koja su arbitrarna ili vezana uz apstraktni materijal (npr. Bruner, Goodnow i Austin, 1956; Wason, 1960, Mynatt, Doherty i Tweney, 1977, 1979; sve prema Klahr, 2000), a značajni broj istraživanja unutar pristupa usmjerenog na procese znanstvenog razmišljanja stavlja naglasak na istraživanje vještina eksperimentiranja i vještina vrednovanja nalaza (Zimmerman, C. 2000, 2005).

Rana istraživanja vještina eksperimentiranja su pokušavala minimalizirati utjecaj prijašnjeg znanja kako bi se usmjerila isključivo na strategije koje ispitanici koriste pri

eksperimentiranju. Ta su se istraživanja odnosila na ćeliju E u Klahrovoj taksonomiji, budući da su istraživala strategije neovisne o području, prije svega izbor strategije kontrole varijabli, odabir prikladnog eksperimentalnog dizajna (testa koji omogućuje valjano zaključivanje) ili stvaranje potpunog skupa kombinacija varijabli u multivarijatnom kontekstu zadatka.

Primjerice, Kuhn i Phelps (1982) prezentirale su djeci četiri epruvete s bezbojnom tekućinom i pokazale da dodavanjem nekoliko kapljica pete tekućine određena kombinacija tekućina mijenja boju. Učenici su trebali otkriti koja kombinacija tekućina je potrebna za postizanje učinka promjene boje. Potraga unutar prostora hipoteza je bila ograničena zadanim ciljem eksperimenata, a znanje o tekućinama nije bilo moguće iskoristiti u postavljanju hipoteza. Uspjeh na zadatku je ovisio isključivo o sposobnosti izoliranja i kontroliranja varijabli u skupu svih mogućih kombinacija tekućina, u cilju određivanja toga koja je tekućina odgovorna za mijenjanje boje.

Dio istraživanja vještina eksperimentiranja bavio se i ćelijom B, jer je djelovao unutar područja koje ispitanici dobro poznaju – svakodnevnog života (npr. Tschirgi, 1980; Sodian, Zaitchik i Carey, 1991).

Bez obzira jesu li se istraživanja vještina eksperimentiranja odnosila na ćeliju E ili B, u ovim istraživanjima ispitanici nisu sami formulirali hipoteze, manipulirali varijablama, niti vrednovali nalaze, budući da im rezultati eksperimenata nisu niti bili prikazani.

Istraživanja vještina vrednovanja nalaza bavila su se sposobnošću učenika da odrede koje hipoteze potvrđuju ili opovrgavaju prikazani podaci (Klahr, 2000). Rana istraživanja vještina vrednovanja nalaza također su koristila zadatke koji se slabo oslanjaju na prethodno znanje, pa se mogu svrstati u ćeliju F Klahrove taksonomije. Ta su istraživanja (npr. Shaklee i Mims, 1981; Shaklee i Paszek, 1985; Shaklee, Holt, Elek i Hall, 1988; sve prema Zimmerman, 2000) tražila od ispitanika da interpretiraju podatke u matricama kovarijacije, u kojima su prezentirani frekvencijski podaci u 2 X 2 kontigencijskim tablicama (prisutan/odsutan «x» X prisutan/odsutan «y»). Ispitanicima se uglavnom sugeriralo da ne uzimaju u obzir znanje koje imaju o predmetu ispitivanja, te ih se usmjeravalo na to da vrednuju samo nalaze iz tablice. U ovim zadacima od učenika se zahtijevalo da vrednuju neku prezentiranu hipotezu u svjetlu podataka iz tablice (deduktivni zadatak) ili da odrede koju hipotezu podržavaju podaci iz tablice (induktivni

zadatak). Ispitanici pritom nisu sami provodili eksperimente, niti su stvarali podatke za analizu, već su zaključke donosili isključivo na temelju prikazanih podataka.

Kasnije su se istraživanja više usmjerila na to kako ispitanici koordiniraju vlastite teorije i podatke o kovarijaciji varijabli pri donošenju zaključaka (ćelije A, C, D i F) (Zimmerman, C. 2000, 2005). Istraživanja u ovom području uglavnom su ispitivala induktivno kauzalno zaključivanje, odnosno sposobnost donošenja zaključaka na temelju predstavljenih kovarijacijskih podataka. Naglasak ovih istraživanja bio je na induktivnim vještinama potrebnim za formuliranje teorija na temelju opaženih obrazaca podataka, kao i na općim inferencijalnim vještinama uključenim u koordiniranje postojećih znanja i vjerovanja s novim nalazima koji ili potvrđuju ili opovrgavaju prethodne teorije. Kuhn, Amsel i O'Loughlin (1988) su, na primjer, ispitanicima prezentirali podatke koji su dijelom potvrđivali, a dijelom opovrgavali njihove prethodne teorije, te su od njih tražili vrednovanje tih kovarijacijskih podataka i kauzalno zaključivanje. U ovom istraživanju korišteni su sadržaji iz svakodnevnog života (zaključivalo se o tome koji čimbenici utječu na dobivanje prehlade), a ispitanici nisu sami provodili eksperimente. I Koslowski (1996) je u svojem radu kombinirala ćelije A, C i F. Učenicima je prikazivala složene sklopove kovarijacijskih podataka, potencijalnih kauzalnih mehanizama, analognih učinaka i alternativnih hipoteza na temelju čega su ispitanici trebalo donijeti zaključke o mogućim kauzalnim čimbenicima.

Na kraju, integrativni pristup znanstvenom razmišljanju podrazumijeva koordinaciju svih ćelija Klahrove taksonomije (Zimmerman, C. 2000, 2005), budući da integrira glavne procese znanstvenog razmišljanja, te da ispituje interakciju znanja specifičnog za područje i strategija neovisnih o području. U istraživanjima u sklopu integrativnog pristupa, o kojima će detaljnije biti riječi u sljedećem poglavlju, koriste se zadaci u kojima ispitanici sudjeluju u svim fazama istraživačkog procesa, unutar područja o kojima učenici posjeduju neke teorije i očekivanja.

## **2.3. Integrativni pristup istraživanjima znanstvenog razmišljanja**

### **2.3.1. Zadaci**

Koncentrirajući se na istraživanja međudnosa pojedinih faza procesa znanstvenog razmišljanja (generiranja hipoteza, eksperimentiranja, vrednovanja nalaza), te na istraživanja interakcija strategija neovisnih o području i znanja specifičnih za područje,

zadaci u sklopu integrativnog pristupa uključuju sve tri glavne faze procesa znanstvenog istraživanja, pa učenici sudjeluju u potpunom ciklusu istraživačkih aktivnosti. Osim toga, integrativni pristup odbacuje korištenje zadataka koji ne zahtijevaju posjedovanje i primjenu postojećih znanja ili očekivanja učenika, ili zadataka u kojima se od učenika traži da zanemaruju vlastito znanje o sadržajima koji se ispituju, pa istraživanja uobičajeno smješta u kontekst konceptualnog znanja u srednje složenim područjima (Zimmerman, 2000). U zadacima se traži multivarijatno kauzalno zaključivanje (Kuhn, 2001b), pa se može reći da zadaci predstavljaju prototip 'pravog' znanstvenog istraživanja u njegovoj najjednostavnijoj, generičkoj formi (Kuhn, 2002a; Kuhn i Franklin, 2006). Zadaci se uobičajeno postavljaju tako da učenici u stvarnoj ili simuliranoj situaciji provode eksperimente i na temelju njih otkrivaju karakteristike kauzalnog modela koji opisuju odnose između nekoliko nezavisnih i jedne zavisne varijable. Manipuliranjem vrijednosti nezavisnih varijabli učenici opažaju promjene u rezultatima na zavisnoj varijabli, i na osnovi toga zaključuju o odnosima između varijabli. U takvom zadatku, učenici sami prikupljaju podatke i odlučuju o vrsti, poretku i broju eksperimenata koje će provesti, te o završetku procesa učenja. Učenici istražuju i uče o postavljenom multivarijatnom kauzalnom sustavu kroz aktivnosti koje sami započinju i kontroliraju, uglavnom uz mala ograničenja, odnosno uz minimalne poticaje postavljene od istraživača. Istraživač uobičajeno ispituje učenika o tome što radi (npr. što predviđa, što zaključuje), ali ne sugerira način rada, niti ne utječe na ispitanika na druge načine (npr. davanjem povratne informacije o točnosti zaključaka). Jedine povratne informacije koje učenik prima tijekom rada na zadatku proizlaze zapravo iz njegovih aktivnosti (Kuhn, 2002b).

Postavljajući hipoteze, osmišljavajući i provodeći eksperimente, te donoseći zaključke o učinku nezavisnih varijabli na zavisnu, učenici konstruiraju, proširuju i restrukturiraju vlastito znanje o predmetu ispitivanja, a ujedno razvijaju istraživačke vještine (Kuhn, 2001b, 2002a, 2002b). Budući da se radi prvenstveno o induktivnom procesu otkrivanja pravila (koja određuju odnose nezavisnih varijabli i zavisne varijable), tijekom kojeg se mijenja repertoar znanja i vještina učenika, o ovakvim zadacima se uobičajeno govori kao o zadacima istraživačkog ili induktivnog učenja (Holland, Holyoak, Nisbett i Thagard, 1986; De Jong i Van Joolingen, 1998; Prins, 2002; Wilhelm i Beishuizen, 2003; Beishuizen, Wilhelm i Schimmel, 2004; Veenman, Wilhelm i Beishuizen, 2004; Veenman i Spaans, 2005; De Jong, 2006).

Također, s obzirom da zadaci pretpostavljaju korištenje kompleksnih procesa koji zahtijevaju aktivno i cilju usmjereno učenje (Klahr, 2000; Kuhn, 2001b), kao i to da učenici istražuju i uče kroz aktivnosti koje sami iniciraju i kontroliraju, ovdje se govori o samoreguliranom (Rheinberg, Vollmeyer i Rollett, 2005) ili samoupravljanom procesu učenja (Zimmerman, C. 2000, 2005).

Zadaci istraživačkog učenja su često računalni, ali mogu biti i realni. Mogu biti relativno jednostavni ili prilično složeni. Na složenost zadatka utječe to iz kojeg su područja korištene varijable, ali je važan i način prezentacije varijabli u zadatku (npr. je li učenicima prikazano koje su varijable nezavisne, a koje zavisne). Povećanje složenosti zadatka postiže se povećanjem broja varijabli i povećanjem broja mogućih eksperimenata. Ukoliko su varijable kontinuirane i kvantitativne (umjesto kategorijalne), također se povećava prostor eksperimenata, a zaključivanje se provodi na temelju podataka koji nalikuju podacima «pravih» znanstvenih istraživanja. Slično tome, složenost zadatka raste ukoliko veličina učinaka nezavisnih varijabli varira među eksperimentima. Složenosti zadatka doprinose i odnosi među varijablama, budući da su linearni odnosi i odnosi bez ograničenja jednostavniji od nelinearnih i interakcijskih odnosa.

Zadaci istraživačkog učenja uobičajeno sadrže odnose varijabli koji su dijelom sukladni, a dijelom nesukladni s prethodnim znanjima i očekivanjima učenika. Takvo postavljanje zadatka je pogodno za istraživanje procesa koordinacije teorija i nalaza, odnosno za utvrđivanje međuzavisnosti prethodnog znanja i zaključivanja na temelju nalaza prikupljenih eksperimentima. Multivarijatni format zadatka pomaže u razmatranju odnosa teorija i nalaza jer učenicima omogućuje visoku razinu slobode u donošenju kauzalnih zaključaka (Kuhn, 1995, 2001b, 2002b). Naime, ukoliko ishod nekog eksperimenta odstupa od očekivanja koje učenik ima na temelju vlastitih teorija o učinku neke varijable, on se lako preusmjerava na druge varijable kako bi objasnio dobiveni ishod.

Ponekad učenici rade na zadatku istraživačkog učenja u jednoj, a ponekad u više situacija<sup>4</sup>, a tad se govori o mikrorazvojnom istraživačkom dizajnu (Kuhn, 1995, 2002b; Granott i Parziale, 2002; Siegler, 2006; Flynn i Siegler, 2007). Taj se dizajn često koristi kod istraživanja istraživačkog učenja jer omogućuje praćenje procesa promjena u znanju o kauzalnoj strukturi modela postavljenog u zadatku i promjena u istraživačkim i inferencijalnim strategijama putem kojih se znanje stječe (Siegler, 2006), odnosno praćenje procesa koordinacije teorija i nalaza (Kuhn, 2001b, 2002b). Istraživačko učenje je

---

<sup>4</sup> U radu se za pojedinu situaciju učenja koristi izraz «mjerenje».

prikladno za ispitivanje mikrorazvojnim istraživanjima, jer strategije koje se koriste u takvim zadacima imaju intrinzičnu vrijednost i ne podliježu suviše motivacijskom problemu koji proizlazi iz ponavljanih prezentacija istog zadatka kroz više situacija učenja (Kuhn, 1995).

### ***2.3.2. Rezultati istraživanja unutar integrativnog pristupa***

Istraživanja unutar integrativnog pristupa znanstvenom razmišljanju pokazuju da učenici u višim razredima osnovne škole imaju nedostatan razvijene vještine potrebne za uspješno eksperimentiranje i zaključivanje, s obzirom da znanstveno razmišljanje zahtijeva složenu koordinaciju različitih kognitivnih i metakognitivnih procesa, te integraciju istraživačkih vještina i konceptualnog znanja (Zimmerman, C. 2005, 2007). Za razvoj i konsolidaciju takvih vještina potrebna je znatna količina vježbe. Nedovoljna razvijenost relevantnih vještina dijelom se pripisuje i malom broju prilika za eksperimentiranje, znanstveno razmišljanje i kritičko mišljenje unutar školskog sustava (Dean i Kuhn, 2003).

Istraživanja kauzalnog zaključivanja u ranom djetinjstvu, kao i istraživanja unutar integrativnog pristupa koja ispituju razvoj znanstvenog razmišljanja na temelju usporedbi djece i odraslih daju, međutim, ponešto drugačije uvide (Kuhn i Franklin, 2006; Sodian i Bullock, 2008; Kuhn, 2009). Dok istraživanja ranih kompetencija pokazuju da djeca pokazuju impresivne vještine kauzalnog zaključivanja već u ranoj dobi, istraživanja koja uključuju multivarijatan kontekst i zahtijevaju od ispitanika koordinaciju novih nalaza i prethodnih teorija, otkrivaju da ni odrasli ne prevladavaju sve poteškoće u znanstvenom razmišljanju pa iskazuju brojne pogreške u eksperimentiranju i pristranosti u zaključivanju (Kuhn i Franklin, 2006). Dok neki istraživači (Li i Klahr, 2006) zaključuju da je razvojna spremnost djece za znanstveno razmišljanje impresivna, drugi (Schauble, 1996) smatraju da je put razvoja strategija i procesa uključenih u znanstveno razmišljanje vrlo dug i zapravo cjeloživotni.

Iako se, na temelju dosadašnjih istraživanja, može reći da su djeca u predadolescentskoj i adolescentskoj dobi spremna razvijati i usavršavati vještine znanstvenog razmišljanja, radi se o vještinama koje se ne razvijaju bez prikladnog obrazovnog iskustva (Kuhn i Pease, 2008; Kuhn i Dean, 2008), odnosno o vještinama čiji razvoj se ne može podrazumijevati sam po sebi (Kuhn, 2005; Kuhn i Franklin, 2006). Zbog toga što zahtijeva svjesno i namjerno koordiniranje brojnih strateških i metastrateških procesa, znanstveno razmišljanje se razlikuje od svakodnevnog kauzalnog rezoniranja (Sodian i Bullock, 2008).



Teško je za učenike, koji imaju problema u svim fazama istraživačkog procesa (Zimmerman, C., 2000, 2005, 2007).

### *Formuliranje istraživačkih pitanja i hipoteza*

U početnoj fazi istraživačkog procesa postavljaju se ciljevi aktivnosti, oblikuju se pitanja koja će biti postavljena i stvara se okvir za faze koje slijede (Kuhn, 2002a). Dakako, ta je početna faza ključna jer organizira i daje smisao i smjer aktivnostima koje slijede (Kuhn, 2005; Kuhn i Dean, 2005). Odmah na početku rada na zadatku istraživačkog učenja, važan izazov s kojim se učenici suočavaju predstavlja prihvaćanje istraživanja kao cilja aktivnosti na zadatku. Uspješnost cjelokupnog istraživačkog učenja određena je time koliko učenici razumiju da postoje neka pitanja koja se mogu postaviti i koliko uspijevaju identificirati ta pitanja (Kuhn, 2001b). Učenici moraju prepoznati da kroz eksperimentiranje dolaze do određenih podataka koji se mogu analizirati i interpretirati na način koji potvrđuje ili opovrgava njihove prethodne teorije o predmetu ispitivanja (Kuhn, 2002a). Ukoliko, pak, učenici ne razumiju da je cilj njihove aktivnosti traženje podataka koji odgovaraju na pitanja čiji odgovori još nisu poznati, istraživački proces postaje prazna aktivnost u kojoj učenici provode eksperimente u svrhu ilustriranja onog što već smatraju točnim (Kuhn i Franklin, 2006; Kuhn i Pease, 2008).

Kad učenici uvide da se eksperimentiranjem dolazi do informacija koje omogućuju zaključivanje, oni tad mogu postaviti pitanja koja omogućuju povezivanje podataka i prethodnih teorija učenika (Kuhn, 2001b, 2002a).

Strategije koje učenici koriste kako bi odgovorili na zahtjeve zadatka karakterizira različiti stupanj prikladnosti i učinkovitosti (Kuhn, 2001b). Na najnižoj razini, nalaze se učenici koji samo provode proceduru koju zahtijeva zadatak («klikaju» sličice i generiraju eksperimente) i nemaju nikakav dublji uvid u cilj zadatka kao istraživačke aktivnosti. U takvom pristupu učenici samo „odrađuju“ eksperimente, na način da isprobavaju različite kombinacije, bez neke namjere ili postojanja plana koji organizira njihov rad (Kuhn, 2002a). Sljedeću razinu predstavlja strategija generiranja poželjnog rezultata kroz eksperimente (npr. postizanje najmanjeg stupnja onečišćenja šuma u zadatku u kojem treba otkriti kako različite varijable utječu na taj stupanj), nakon koje dolazi do preokreta prema strategijama koje predstavljaju pravi istraživački pristup. U osnovnom obliku taj se pristup očituje u razmatranju razlika u ishodima eksperimenata ovisno o različitim kombinacijama nezavisnih varijabli, dok se u naprednijim oblicima usmjerava na analizu toga što dovodi

do razlika u ishodima, te, konačno, na analizu učinka pojedine nezavisne varijable na rezultate eksperimenata.

Istraživanja potvrđuju da je razvijanje osvještenosti i shvaćanja cilja zadatka (kao onog u kojem se ispituje učinak pojedinih varijabli) važno za unaprjeđivanje ostalih faza istraživačkog procesa. Pokazuje se da je za poticanje korištenja valjanih strategija eksperimentiranja već dovoljno kratko upućivanje učenika na početku rada na to da se usmjere samo na jedan čimbenik (Kuhn i Dean, 2005).

Istraživanja pokazuju da učenici, posebice djeca, na zadatku istraživačkog učenja često rade tako da reproduciraju poželjni ishod i eliminiraju negativni učinak, umjesto da se usmjeravaju na traženje veza među varijablama (Kuhn i Phelps, 1982; Schauble, 1990). Carey i suradnici (1989) navode da učenici ne razlikuju što znači razumjeti, a što reproducirati pojavu (prema Zimmerman, C. 2005, 2007). Na postizanje pozitivnih ishoda eksperimenata učenici se uobičajeno usmjeravaju na početku rada na zadatku, kad za njih «utjecati» znači «pomaže ostvariti poželjan ishod» (Kuhn i sur., 1992, 1995). Tada učenici često toleriraju da neka varijabla ima utjecaj u nekim situacijama (kad je ishod poželjan), a nema utjecaj u drugim situacijama (kad je ishod negativan). Kuhn i Pease (2008) nalaze da se učenici i u kasnijim fazama rada na zadatku s istraživačkog i analitičkog fokusa često vraćaju na generiranje pozitivnih ishoda kao cilja vlastite aktivnosti, pa zaključuju da je održavanje svijesti o cilju istraživanja jedan od najvećih izazova s kojima se učenici suočavaju u procesu istraživačkog učenja.

Ovisno o tome kakav cilj učenici postavljaju na zadatku istraživačkog učenja, Schauble Klopfer i Raghavan (1991) razlikuju inženjerski pristup i znanstveni pristup. Učenici koji zauzimaju inženjerski pristup rade na zadatku tako da pokušavaju reproducirati ishod koji smatraju poželjnim. Često se usmjeravaju na čimbenike koje smatraju kauzalnima i rade principom «probaj i vidi što će se dogoditi». S druge strane, kad učenici zauzimaju znanstveni pristup rade sustavnije, vode se prethodnim teorijama, ali analiziraju učinak svake pojedine varijable, s ciljem utvrđivanja koje varijable imaju, a kojem nemaju utjecaj. Nije, međutim, jasno koliko su ta dva različita pristupa radu na zadacima istraživačkog učenja karakteristika osobe, a koliko su uvjetovani zahtjevima zadatka ili implicitnim pretpostavkama o njemu. Smatra se ipak da je inženjerski pristup tipičan u vrijeme kad se istraživačke vještine tek razvijaju (Zimmerman, C. 2005, 2007).

Osim zauzimanja znanstvenog pristupa pri radu na zadatku istraživačkog učenja i shvaćanja zadatka kao onog u kojem treba otkriti učinke pojedinih nezavisnih varijabli, za uspješno istraživačko učenje je potrebno da učenici jasno identificiraju istraživačka pitanja, odnosno oblikuju hipoteze koje ih upućuju na njihovu provjeru.

Podrazumijeva se da u trenutku kad počinju raditi na zadatku istraživačkog učenja, učenici već imaju neko znanje o području koje je predmet istraživanja, kao i neke hipoteze o tome kako funkcionira model koji se zadatkom ispituje. Pokazuje se da učenici stvaraju teorije o mogućim učincima nezavisnih varijabli, čak i u područjima koja im nisu poznata (Wilhelm i Beishiuzen, 2003). Te početne hipoteze su važne jer utječu na proces eksperimentiranja i donošenja zaključaka, tako da usmjeravaju izbor hipoteza koje će se testirati i određuju to koliko će im se vremena i pažnje posvetiti pri eksperimentiranju (Schauble, 1996).

Istraživanja ukazuju na probleme učenika u procesu formuliranja istraživačkih pitanja i hipoteza (Zimmerman, C. 2005, 2007). Učenici često ne znaju kako bi hipoteze trebale biti postavljene (De Jong i Van Joolingen, 1998), pa često ne specificiraju varijable koje ih zanimaju, niti uspostavljaju neki odnos među njima, a imaju i tendenciju izbjegavanja preciznih hipoteza koje bi mogle biti odbijene (De Jong i Van Joolingen, 1998; Keselman i Kuhn, 2002; Keselman, 2003).

Posebice je za mlađu djecu karakteristično da provode eksperimente bez formuliranja eksplicitnih hipoteza (Penner i Klahr, 1996; prema Zimmerman, C. 2005, 2007). Uz to što specificiraju manje hipoteza od starijih ispitanika, za djecu je također tipično da uopće ne postavljaju složene hipoteze (Wilhelm, Beishuizen i Van Rijn, 2005), a imaju i tendenciju usmjeriti se samo na plauzibilne hipoteze, i uporno se baviti samo jednom od njih (Klahr, Fay i Dunbar, 1993). Za razliku od toga, odrasli su spremni razmotriti više hipoteza (Klahr i sur., 1993).

Konačno, istraživanja pokazuju da prethodna očekivanja i teorije učenika o sadržaju zadatka utječu na to koje će se hipoteze prvo ispitati, koje će se ponavljano ispitivati i koliko će im se učenici posvetiti u istraživačkom procesu (Zimmerman, C. 2005). I djeca i odrasli češće počinju istraživati osvrćući se na varijable koje smatraju kauzalno povezanim s ishodima, odnosno baveći se onima koje su konzistentne s njihovim prijašnjim znanjima i vjerovanjima (Schauble, 1990, 1996), a tek kasnije počinju razmatrati hipoteze o nekauzalnim varijablama (Kuhn i sur, 1992, 1995; Schauble, 1990, 1996). U skladu s tim, učenici češće postavljaju standardne ili očekivane hipoteze, nego

hipoteze koje pokušavaju objasniti aberantne ili neočekivane rezultate (Echevarria, 2003; prema Zimmerman, C. 2005, 2007). Konačno, učenici često ne mogu razviti alternativne hipoteze za objašnjenje neke pojave, već se drže jednog objašnjenja kojeg smatraju apsolutno točnim (Kuhn i Dean, 2005).

### *Eksperimentiranje*

Eksperimentiranje može imati dvije osnovne svrhe: s jedne strane, može imati za cilj testiranje postojećih hipoteza (deduktivna svrha), a, s druge strane, može služiti prikupljanju informacija kako bi se indukcijom došlo do hipoteze koja može objasniti obrazac prikupljenih nalaza (induktivna svrha) (Klahr i Dunbar, 1988). Koja god bila svrha, potrebno je da učenik prepozna da se procesom eksperimentiranja prikupljaju podaci koji služe kao nalazi koji se mogu povezati s njegovim prethodnim teorijama i hipotezama. Kako bi proces vrednovanja nalaza bio jednostavan i valjan, potrebno je u procesu eksperimentiranja izolirati varijable tako da se mogu odbaciti alternativne hipoteze. Strategija kontrole varijabli i sustavno variranje varijabli (provođenje kompletnog skupa kombinacija) ključne su vještine eksperimentiranja (Chen i Klahr, 1999). Strategiju kontrole varijabli imenovali su Inhelder i Piaget 1958. godine. Drugi naziv za tu strategiju koji se koristi u literaturi jest «variraj jednu varijablu u jednom trenutku» (engl. *VOTAT 'vary one thing at a time'*; Tschirgi, 1982). Korištenje strategije kontrole varijabli sužava mogući prostor eksperimenata i predstavlja jedinu strategiju neovisnu o području koja omogućuje valjano zaključivanje, budući da dovodi do nalaza koji su interpretabilni (Klahr, 2000). Eksperimenti koji nisu sustavno varirani i koji ne izoliraju varijable (jednu po jednu) dovode do nalaza koji ne mogu biti jednoznačno interpretirani, čime se onemogućuje donošenje valjanih (ne)kauzalnih zaključaka i razvoj znanja o predmetu ispitivanja. Osim variranja više od jedne varijable po eksperimentu, nevaljane strategije su «drži jednu varijablu konstantnom u jednom trenutku» (engl. *HOTAT 'hold one thing at a time'*) i «promijeni sve». Dok prva strategija u sukcesivnim eksperimentima mijenja sve razine varijable osim razinu jedne varijable, druga strategija nesustavno mijenja sve varijable.

Rezultati istraživanja pokazuju da učenici često imaju tendenciju nesustavnog variranja varijabli, provode nekontrolirane pokuse i eksperimente na osnovi kojih ne mogu testirati svoje hipoteze. Takvo je eksperimentiranje učestalije kod djece, ali je prisutno i kod odraslih (npr. Kuhn i sur., 1995; Schauble, 1996).

Pri eksperimentiranju, odrasli češće od djece ograničavaju prostor mogućih eksperimenata na one koji su informativni (Klahr i sur., 1993). Odrasli biraju širi raspon eksperimenata tj. bolje pokrivaju prostor eksperimenata, dok djeca češće nenamjerno ponavljaju iste eksperimente (Schauble, 1996). Djeca posvećuju više eksperimenata varijablama koje već razumiju, a odrasli se lakše pomiču prema ispitivanju onih varijabli čije odnose još ne razumiju (Klahr i sur., 1993; Schauble, 1996). Eksperimentiranje koje provode djeca tako karakterizira manja informativnost, kao i češće korištenje eksperimenata u svrhu dokazivanja točnosti vlastitih teorija i očekivanja.

Istraživanja također pokazuju da vrsta ishoda određuje strategiju eksperimentiranja koju zauzimaju učenici (Tschirgi, 1980), čime se pokazuje da izbor eksperimentalnog dizajna ovisi o prethodnom iskustvu učenika i njihovom znanju iz područja. Kad postoji pozitivan ishod, učenici traže potvrđujuća opažanja, žele reproducirati učinak i zadržati varijable koje smatraju odgovornima za dobar rezultat, pa pri manipulaciji varijabli koriste strategiju «drži jednu varijablu konstantnom u jednom trenutku». U ovakvoj situaciji, učenici podrazumijevaju da je zadatak istražiti uvjete pod kojima se pozitivan učinak pojavljuje, pa uvjereni u kauzalni status pojedine varijable za postizanje dobrog rezultata, pokušavaju pokazati da se taj pozitivan rezultat pojavljuje bez obzira na status drugih varijabli. Za razliku od toga, kad je ishod negativan, učenici biraju dokaze koji ga opovrgavaju, traže jednu varijablu odgovornu za loš ishod kako bi je eliminirali, pa koriste zapravo valjaniju strategiju «variraj jednu varijablu u jednom trenutku».

Istraživanja također utvrđuju da i djeca i odrasli pokazuju intraindividualne varijacije u uporabi strategija eksperimentiranja (Kuhn, 1995; Kuhn i sur., 1995). U repertoaru dostupnih strategija učenici imaju različite strategije koje se međusobno razlikuju po stupnju prikladnosti (Kuhn, 2002b). Učenici uobičajeno počinju rad na zadatku nesustavnim variranjem varijabli i korištenjem nevaljanih usporedbi, ali s ponavljanim situacijama učenja (unutar mikrorazvojnog konteksta) počinju koristiti i strategiju kontrole varijabli (Kuhn i sur., 1995). Ta valjana strategija ne zamjenjuje nevaljane strategije naglo, već učenici u isto vrijeme koriste različite strategije eksperimentiranja, a često se i vraćaju na manje napredne strategije. Istraživanja pokazuju da istovremena prisutnost više strategija i varijabilitet u korištenju strategija nisu ograničeni na djecu ili na periode intenzivnih razvojnih promjena, već se mogu smatrati dijelom normativnog funkcioniranja (Kuhn i sur., 1995).

Nadalje, već su rana istraživanja vještina eksperimentiranja (npr. Kuhn i Phelps, 1982) pokazala da u uvjetima vježbe ili treninga učenici mogu razviti vještine eksperimentiranja i naučiti kako sustavno kombinirati varijable i koristiti strategiju kontrole varijabli. S ponavljanim eksperimentiranjem, ne povećava se samo valjanost eksperimentiranja, već i razumijevanje toga zašto su valjane strategije eksperimentiranja učinkovite, dakle, jača metastrateško razumijevanje. I novija mikrorazvojna istraživanja Kuhn i suradnika (1992, 1995, 2000) i Schauble (1996) potvrđuju taj nalaz i pokazuju da učenici uspješno razvijaju vještine eksperimentiranja kad samoupravljanom eksperimentiraju na zadacima istraživačkog učenja kroz duže vrijeme.

Druga istraživanja (Chen i Klahr, 1999; Klahr, Chen i Toth, 2001; Klahr i Nigam, 2004; Klahr i Li, 2005) ukazuju, pak, na uspješnost kratkog direktnog poučavanja strategije kontrole varijabli pa zagovaraju takav pristup kao najučinkovitiju metodu jačanja istraživačkih vještina. U novije se vrijeme u literaturi mnogo raspravlja o tome kojoj metodi dati prednost – direktnom poučavanju vještina eksperimentiranja ili samostalnom istraživačkom učenju (Kuhn i Dean, 2005; Dean i Kuhn, 2006; Kirschner, Sweller i Clark, 2006; Kuhn, 2007b; Hmelo-Silver, Golan Duncan i Chinn, 2007; Chen i Klahr, 2008; Strand-Cary i Klahr, 2008; Klahr, 2009).

#### *Vrednovanje nalaza te promjene u znanju*

U fazi vrednovanja nalaza, analizom prikupljenih podataka i otkrivanjem obrazaca u njima, učenici dolaze do zaključaka o odnosima između pojedinih varijabli. Pritom, podaci prikupljeni eksperimentima trebaju biti reprezentirani i analizirani kao nalazi koji se mogu povezati s prijašnjim teorijama učenika o predmetu ispitivanja, ali koji su od njih neovisni (Kuhn, 2001b, 2002b). Uspješna koordinacija teorija i nalaza podrazumijeva da su podaci prikupljeni eksperimentima i teorije koje učenici već posjeduju mentalno reprezentirani kao zasebni entiteti (objekti kognicija) i da učenici konstruiraju odnos među njima, razumijevajući implikacije koje nalazi imaju za potvrđivanje i opovrgavanje postojećih teorija, te prilagođujući teorije nalazima na svjestan i refleksivan način.

Podrazumijeva se da učenici unose vlastite teorije i prethodna znanja u nove situacije učenja, pa učenje ne predstavlja samo potragu za novim činjenicama koje se dodaju na postojeći skup ideja, već na složeni proces koordiniranja postojećih teorija s novim nalazima. Strategije koje učenici koriste u fazi vrednovanja nalaza upravo ukazuju na pokušaje koordinacije prethodnih teorija i prikupljenih podataka (Kuhn, 2001b, 2002b).

Manje napredne strategije uključuju ignoriranje nalaza i temeljenje zaključaka isključivo na vlastitim teorijama koje učenik već posjeduje, mijenjanje nalaza tako da odgovaraju postojećim teorijama, te selektivno obraćanje pažnje na određene nalaze koji su u skladu s postojećim teorijama i interpretiranje tih pojedinih primjera kao ilustracije vlastitih teorija i potvrde ispravnosti tih teorija, dok se zanemaruju opovrgavajući nalazi. U slučajevima gdje su dominantne te manje napredne strategije, učenici često nisu svjesni da su prikupljeni nalazi različiti od njihovih teorija, već smatraju da su nalazi konzistentni s njihovim očekivanjima (Kuhn, 2002a). U takvim uvjetima, novi podaci mogu čak i promijeniti postojeće teorije, ali učenik nije svjestan da do toga dolazi, niti može točno identificirati izvor svog znanja.

Uz naprednije strategije vrednovanja nalaza vezan je veći utjecaj podataka, koji mogu djelovati na teorije, prilagođavati ih i mijenjati. Napredniju strategiju predstavlja već usporedba odabranih primjera podataka u cilju potvrđivanja pojedine teorije, dok najnapredniju strategiju predstavlja usporedba najmanje dva eksperimenta koji omogućuju testiranje teorije (Kuhn, 2001b, 2002b).

U ovoj fazi rada na zadatku istraživačkog učenja, u kojoj analiza i vrednovanje nalaza dovodi do zaključaka o (ne)postojanju kauzalnih odnosa između varijabli, potrebno je donijeti zaključke koji su utemeljeni na nalazima (valjani zaključci<sup>5</sup>), i inhibirati one koji to nisu, te priznati nemogućnost donošenja zaključaka u slučaju postojanja nekontroliranih usporedbi. Inferencijalne strategije koje se koriste za to razlikuju se s obzirom na njihovu prikladnost, kao i u drugim fazama rada na zadatku (Kuhn, 2001b, 2002b). Budući da teorijska očekivanja učenika mogu utjecati na pristranosti u zaključivanju kao i u fazi analize podataka, mogućnosti za inferencijalne pogreške ostaju velike (Kuhn i Franklin, 2006). Najnižu razinu inferencijalnih strategija čine tzv. teorije u akciji koje predstavljaju tvrdnje o odnosima među varijablama koje su sasvim utemeljene na prethodnim teorijama učenika, bez bilo kakve svijesti o razlikovanju teorija i nalaza, kao i bez ikakvih naznaka procesiranja podataka prikupljenih kroz eksperimentiranje. Naprednije strategije uključuju reprezentiranje tvrdnji o učincima nezavisnih varijabli kao zasebnih entiteta i pokazuju sve uspješniju koordinaciju teorija i nalaza - od tvrdnji koje nisu pokrepljene nalazima, preko

---

<sup>5</sup> Valjani zaključak je onaj koji točno opisuje učinak pojedine nezavisne varijable na zavisnu, a koji je donesen na temelju usporedbe barem dva eksperimenta koji se međusobno razlikuju samo u razini varijable čiji učinak se ispituje. Nevaljani zaključak može biti točan ili netočan, a donesen je ili bez razmatranja nalaza, ili na temelju samo jednog eksperimenta, ili na temelju usporedbe eksperimenata u kojima varijabla čiji učinak se ispituje nije niti varirana, ili na temelju usporedbe eksperimenata u kojima su dvije ili više varijable mijenjane na nekontroliran način.

onih s ilustrativnim nalazima, do onih koje se oslanjaju samo na potvrđujuće nalaze. Najnaprednija strategija ukazuje na potpuno razvijene vještine koordiniranja teorija i nalaza, što podrazumijeva da učenici razumiju da se novi nalazi vrednuju s obzirom na implikacije koje imaju za postojeće teorije učenika, sa svjesnošću da se teorije mogu revidirati, ukoliko postoji raskorak između nalaza i prethodnih teorija (Kuhn, 2002a).

Rezultati istraživanja pokazuju da su učenici, kad interpretiraju i vrednuju nalaze eksperimenata, pod utjecajem vlastitih teorija. Koordinacija teorija i nalaza je posebice problematična ukoliko učenici imaju snažna prijašnja vjerovanja, kakva se, primjerice, opažaju u socijalnim područjima (Kuhn i sur., 1995). U takvim slučajevima učenici reagiraju drugačije na nalaze koji potvrđuju i na nalaze koji opovrgavaju njihova vjerovanja. Učenici imaju problema u odbacivanju vlastitih teorija, te pokazuju tendenciju ignoriranja, odbacivanja ili iskrivljavanja podataka koji se ne uklapaju u njihove teorije (Kuhn i sur., 1988; 1995). Posebice djeca imaju poteškoća u vrednovanju nalaza koji se ne slažu s njihovim prethodnim vjerovanjima (Kuhn, Schauble i Garcia-Mila, 1992; Kuhn i sur., 1995). To je naročito slučaj ukoliko prijašnje teorije učenika govore o kauzalnom odnosu nezavisne i zavisne varijable. Stoga je uobičajeno da u situaciji kad se susretnu s nalazima koji opovrgavaju prethodne kauzalne teorije učenika, učenici pokazuju nesklonost odbacivanja tih teorija. Tada dolazi do nevaljanih kauzalnih zaključaka – učenici smatraju neku varijablu kauzalnom, a ona ustvari nije povezana s ishodom.

Nadalje, u istraživanjima se pokazuje da učenici, posebice djeca, imaju tendenciju često mijenjati zaključke, te donositi kauzalne zaključke na temelju nedovoljnih i neinformativnih pokusa, na temelju jednog slučaja kovarijacije između nezavisnih varijabli i ishoda, pri čemu zajedničko pojavljivanje jedne razine varijable i jednog ishoda predstavlja znak da su oni kauzalno povezani, usprkos prisustvu drugih kovarijata (Klahr i sur., 1993; Kuhn i sur., 1995; Schauble, 1996). U situaciji u kojoj se zajedničko pojavljivanje jedne razine varijable i ishoda smatra dovoljnim dokazom za postojanje povezanosti te varijable i ishoda, uglavnom se implicira da kauzalnu ulogu nema varijabla, nego razina varijable npr. na uništenost šuma ne utječe udaljenost šuma od naselja, već *«kad je šuma blizu naselja utječe, a kad je daleko ne utječe»* (Kuhn i sur., 1995). Učenici često miješaju pojmove 'varijable' i 'razine varijable', pa smatraju da varijabla ima učinak ako je njezina razina povezana s visokim rezultatom, ali da nema razlike ukoliko se pojavljuje s niskim rezultatom (Kuhn, Pease i Wirkala, 2009). Čak i kad se učenike



Podsjeća da varijabla, a ne razina varijable ima ili nema utjecaj na rezultat, oni nastavljaju s takvim objašnjenjima.

Istraživanja koja uspoređuju djecu i odrasle na zadacima istraživačkog učenja pokazuju da su odrasli također pod utjecajem prijašnjih vjerovanja, ali pokazuju veću kognitivnu fleksibilnost nego djeca, bolje koordiniraju prethodne teorije i prikupljene nalaze, te bolje razumiju implikacije koje nalazi imaju za teorije (Kuhn, 2001b). Dok djeca ponekad uopće ne procesiraju nalaze pa zaključke donose bez oslanjanja na podatke, ili nakon jednog jedinog eksperimenta (obično onog zadnje provedenog), odrasli su manje skloni prekidati rad vrlo rano u procesu učenja i donositi preurane zaključke, bez referenci na nalaze (Kuhn i Dean, 2004a). Oni češće traže rezultate više eksperimenata i skloniji su temeljiti svoje kauzalne zaključke na usporedbi više eksperimenata. Osim toga, nekonzistentne nalaze više pokušavaju osmisliti nego ignorirati, a više su skloni i razmatrati veći broj hipoteza. Iako i odrasli pokazuju tendenciju sjedinjenja nalaza i teorija u jedinstvenu reprezentaciju toga «kakve stvari jesu», pri čemu nove informacije prihvaćaju kao ilustraciju toga realiteta, za odrasle je ipak karakteristično bolje razlikovanje teorija i nalaza (Kuhn i Franklin, 2006).

Istraživanja, nadalje, pokazuju da je i za djecu i odrasle teže integrirati nalaze koji nisu u skladu s prethodnim kauzalnim teorijama, nego nalaze koji se ne slažu s prijašnjim nekauzalnim teorijama (Zimmerman, C. 2005, 2007). U prvom slučaju zahtijeva se restrukturiranje sustava vjerovanja (akomodacija), a u drugom inkorporiranje novo otkrivene kauzalne veze (asimilacija) (Koslowski, 1996). Kad eksperimentalni nalazi kažu da je neka varijabla u kauzalnom odnosu s ishodom (a učenik je vjerovao da ona nema utjecaja), učenik će lakše prihvatiti taj nalaz kao uvjerljiv, nego u situaciji kad otkrije da neka varijabla «nema veze» (a učenik je mislio da utječe na ishod). Jedan jedini eksperiment koji pokazuje da varijabla ima utjecaja (bez obzira očekivano ili ne) može biti dovoljan za mijenjanje teorije ispitanika iz nekauzalne u kauzalnu (Zimmerman, C. 2005, 2007).

U početnom istraživačkom učenju, u prvim situacijama učenja, i djeca i odrasli se uobičajeno usmjeravaju na čimbenike za koje vjeruju da su kauzalno povezani s ishodom, te ignoriraju pretpostavljene nekauzalne čimbenike (Schauble, 1990; 1996), pa je za početno učenje karakteristično postojanje mnogo (nevaljanih) inkluzivnih zaključaka. Tek u kasnijim fazama rada na zadatku, učenici se od inkluzivnih hipoteza i zaključaka,

postepeno usmjeravaju i na ekskluzivne zaključke i zaključke o nemogućnosti određivanja kauzalnosti (Kuhn i sur., 1995; Schauble, 1996; Keselman, 2003).

Odrasli, u odnosu na djecu, češće donose ekskluzivne zaključke kao i one koji kažu da se zaključak ne može donijeti, iako i kod njih dominiraju inkluzivni zaključci (Schauble, 1996). Djeca imaju problema sa zaključivanjem o varijablama koje ne variraju zajedno s ishodom (Kanari i Millar, 2004). U slučajevima kad nezavisna varijabla nije povezana sa zavisnom, učenici su skloni selektivno opažati podatke i selektivno ih koristiti, iskrivljavati ili reinterpretirati, odnosno izjaviti da se na temelju provedenih pokusa ne može ništa zaključiti o odnosu varijabli. Već je u ranim istraživanjima vrednovanja nalaza (Kuhn, Amsel i O'Loughlin, 1988) utvrđeno da kad su učenici pitani da generiraju nalaze koji pokazuju da neki čimbenik nema utjecaj na ishod, oni uobičajeno navode kovarijacijski nalaz u suprotnom smjeru od onog koji se može predvidjeti na temelju njihove kauzalne teorije o tom čimbeniku.

Teškoće s ekskluzivnim zaključcima tumače se većom izloženošću varijablama koje su kauzalne unutar nastave prirodnoznanstvenih predmeta, većim iskustvom s donošenjem inkluzivnih zaključaka (Kanari i Millar, 2004; prema Zimmerman, C. 2005, 2007), ali i tvrdnjom da su valjani ekskluzivni zaključci, kao i oni koji govore da se zaključak ne može donijeti, konceptualno složeniji jer zahtijevaju od ispitanika da uzmu u obzir nizove provedenih eksperimenata (Kuhn i sur., 1995; Schauble, 1996), za što učenici nemaju dovoljno razvijenu metamemoriju.

Istraživanja, nadalje, pokazuju da i djeca i odrasli pri kauzalnom zaključivanju ne koriste samo kovarijacijske nalaze, već se služe vlastitim teorijama o uzrocima i kauzalnim mehanizmima koji se nalaze u osnovi odnosa među varijablama (Schauble, 1996; Koslowski i Masnick, 2002). Pokazuje se da učenici pri vrednovanju nalaza uzimaju u obzir mehanizme koji mogu objasniti kauzalne odnose i često imaju potrebu objasniti zašto su obrasci nalaza njima logični ili plauzibilni. Učenici i spontano iskazuju moguće kauzalne mehanizme, u situacijama kad to nije zahtjev zadatka. Učenici tretiraju kovarirajući čimbenik kao kauzalni kad postoji mehanizam kojim mogu objasniti kako je čimbenik doveo do učinka, a tome su manje skloni kad nema plauzibilnog kauzalnog mehanizma u podlozi (Kuhn, Amsel i O'Loughlin, 1988; Koslowski, 1996). Štoviše, kad su uz postojanje velikog broja kovarijacijskih nalaza prisutni i mogući mehanizmi koji ih objašnjavaju, to se uzima kao pokazatelj kauzalnosti, bez obzira radi li se plauzibilnim ili neplauzibilnim kovarijacijama (Koslowski, 1996).

Raspravljajući o izvorima lošeg učinka učenika na zadacima istraživačkog učenja Kuhn, Black, Keselman i Kaplan (2000) navode da je on rezultat pogrešnog mentalnog modela multivarijatne kauzalnosti koji je tipičan u dječjoj dobi. Autori smatraju da učenici u višim razredima osnovne škole, a ponekad i nakon toga, ne razumiju da su učinci pojedinih varijabli na ishod konzistentni i aditivni (Kuhn i sur., 2000; Kuhn, 2002a; Keselman, 2003). Učenici ne podrazumijevaju da varijabla koja proizvodi učinak u jednoj situaciji mora proizvoditi isti učinak u drugoj situaciji, ukoliko su drugi uvjeti isti. Također ne podrazumijevaju da se učinci različitih čimbenika međusobno kombiniraju tj. da je ukupni učinak suma svih individualnih učinaka koji djeluju. Učenici obično precjenjuju utjecaj neke varijable, percipiraju tu varijablu kao odgovornu za ishod, a ignoriraju ostale. Za objašnjavanje ishoda dovoljno im je istovremeno pojavljivanje te jedne (razine) varijable i ishoda. Potencijalni uzročni utjecaj drugih varijabli ne tretira se kao aditivni, već se uzima kao drugo objašnjenje za kasniji ishod, ili se isključuje zbog «dokazanog» utjecaja prve varijable. Takvi netočni modeli kauzalnosti onemogućuju valjanu kauzalnu analizu i limitiraju prihvaćanje cilja i strategija eksperimentiranja i zaključivanja potrebnih za učinkovito znanstveno razmišljanje (Kuhn, 2002a; Keselman i Kuhn, 2002). Naime, bez shvaćanja konzistentnosti učinka varijabli, učenici ne mogu razumjeti važnost usporedbe eksperimenata u cilju identificiranja učinka pojedine varijable, a bez razumijevanja aditivne prirode kauzalnih utjecaja, učenici ne mogu razumjeti potrebu kontroliranja pomiješanih učinaka različitih varijabli, jer ih nisu niti svjesni.

Novija istraživanja Kuhn i suradnika upravo i pokazuju da glavnu poteškoću učenicima ne predstavlja utvrđivanje učinaka pojedinih nezavisnih varijabli, već multivarijatno predviđanje u sklopu kojeg učenici trebaju istovremeno uzeti u obzir kauzalne učinke više nezavisnih varijabli (Keselman i Kuhn, 2002; Kuhn i Dean, 2004a; Kuhn, 2005, 2007a; Kuhn i Pease, 2008; Kuhn i sur., 2009). Ta istraživanja pokazuju da se vještina rezoniranja o simultanom djelovanju više nezavisnih varijabli razvija vrlo sporo i predstavlja velik konceptualni problem čak i za učenike koji su svladali valjano eksperimentiranje putem strategije kontrole varijabli. I odrasli i djeca su skloni pri predviđanju ishoda eksperimenata na temelju kombinacija nezavisnih varijabli uzeti u obzir kauzalne učinke samo nekih varijabli, a zanemariti učinke drugih kauzalnih varijabli, pa su spremni atribuirati ishod eksperimenta samo jednom kauzalnom čimbeniku. U objašnjenju toga koje varijable utječu na predviđeni ishod eksperimenta, učenici uobičajeno navode manji broj varijabli, nego što su prethodno identificirali kroz analizu učinaka pojedinih varijabli.

To se događa čak i kad je učenicima dat podsjetnik o tome ima li pojedina varijabla ili ne učinak na rezultat (Kuhn, Iordanou, Pease i Wirkala, 2008).

Osim sklonosti davanja prevelike važnosti jednom kauzalnom čimbeniku, učenici su skloni nekonzistentnom atribuiranju, pa u predviđanju ishoda eksperimenta u sljedećem slučaju spremno odustaju od prvog kauzalnog čimbenika i okreću se nekom drugom. Sve to navodi da učenici ne razumiju konzistentnost i aditivnost učinaka, što reflektira njihov nezreli mentalni model multivarijantne kauzalnosti (Kuhn, 2007a).

Na kraju, mikrorazvojna istraživanja pokazuju da nakon ponavljanih situacija učenja učenici pokazuju povećanje broja valjanih usporedbi, valjanih zaključaka i objašnjenja na temelju podataka (npr. Kuhn i sur., 1992, 1995; Schauble, 1996). Učenici počinju razlikovati informativne i neinformativne eksperimente i provoditi kontrolirane usporedbe, što olakšava zaključivanje. Kao i kod eksperimentiranja, i u zaključivanju se opaža intraindividualni varijabilitet – tijekom rada na zadatku miješaju se valjani i nevaljani zaključci, jača valjano, a slabi nevaljano zaključivanje.

Dakako, povećanjem valjanih strategija eksperimentiranja i zaključivanja raste razumijevanje kauzalnog modela predstavljenog zadatkom tj. dolazi do povećanja znanja o odnosima ispitivanih varijabli. Među strategijama (procesima) i znanjima (sadržajima) postoji dinamički odnos pa promjene u znanju podržavaju promjene u strategijama i obrnuto. Prikladno znanje utječe na izbor prikladnih strategija eksperimentiranja, a sustavno i valjano eksperimentiranje osigurava razvoj točnijeg i cjelovitijeg znanja (Zimmerman, C. 2005, 2007).

#### *Varijabilitet u izvedbi i metakognitivno znanje*

U prethodnom poglavlju već je istaknuto da mikrorazvojna istraživanja sugeriraju da tijekom istraživačkog učenja učenici pokazuju intraindividualne varijacije u korištenju strategija eksperimentiranja i zaključivanja, koje nisu ograničene na neka kratka prijelazna razdoblja, već se mogu smatrati karakteristikom ljudskog organizma u svim vremenima i svim okruženjima (Kuhn, 2001b). Mikrorazvojna istraživanja ukazuju na varijabilitet kao na osnovnu karakteristiku kognitivnog funkcioniranja i u drugim područjima istraživanja (Siegler i Shipley, 1995; Siegler, 2007).

U svim fazama rada na zadacima istraživačkog učenja, učenici odjednom posjeduju više strategija, uz koje se veže različita vjerojatnost pojavljivanja u repertoaru ponašanja učenika, te različiti stupanj učinkovitosti i djelotvornosti. Na jednom ekstremu nalaze se

kontraproduktivne, a na drugom optimalno učinkovite i djelotvorne strategije (Kuhn, 2001b). U repertoaru ponašanja učenika mogu se pojaviti nove strategije, a polako nestajati neke stare, ali učenici ne pokazuju iznenadni napredak od nevaljanih strategija prema naprednijim strategijama. Bolje strategije se pojavljuju postupno, i ne zamjenjuju odmah i uvijek manje napredne strategije, već se paralelno pojavljuju u repertoaru ponašanja kroz duže vrijeme. Razvoj se upravo sastoji u mijenjaju frekvencije s kojom se različite strategije pojavljuju. Siegler takav model promjena naziva modelom preklopljenih valova (Siegler, 2000; 2006), s obzirom da u svakoj vremenskoj točki neka strategija jača po frekvenciji pojavljivanja, neka slabi, dok neka ostaje stabilna. Pritom, najveći izazov ne predstavlja svladavanje novih strategija, nego ukidanje (inhibicija) starijih i poznatijih, ali nevaljanih strategija rada (Kuhn, 2001b, 2002b). Ta dva procesa, pojavljivanje novih, boljih strategija i nestajanje starih, inferiornijih strategija, događaju se neovisno jedan o drugom, barem kad je riječ o inferencijalnim strategijama u kontekstu multivarijatnog kauzalnog zaključivanja (Kuhn i Pease, 2010).

Mikrorazvojna istraživanja također pokazuju da učenici pokazuju napredak u vještinama istraživanja čak i bez direktnog poučavanja, u situacijama kad se višestruko izlažu situacijama koje od njih zahtijevaju primjenu takvih vještina (Kuhn, 1995, 2001b, 2002b; Schauble, 1990, 1996). U situacijama višekratnog izlaganja situacijama učenja povećava se broj valjanih usporedbi i valjanih zaključaka (Chen i Klahr, 1999; Kuhn i Dean, 2005). S obzirom da već i učenje bez direktnog poučavanja kod velikog dijela učenika vodi generiranju novih strategija i poboljšanom izvođenju postojećih strategija, smatra se da sam proces učenja može biti izvor novog učenja (Siegler, 2006). Osim ponavljanja situacija učenja, promjene mogu potaknuti i drugi mehanizmi, npr. davanje povratne informacije o točnosti zaključivanja, direktna poduka o strategijama eksperimentiranja, socijalna kolaboracija, zahtjev za samo-objašnjenjima strategija rada i slično.

Jedno objašnjenje procesa promjena u eksperimentiranju i zaključivanju kaže da je jačanje novih strategija vjerojatno posljedica uvježbavanja izvedbe novih strategija, odnosno potkrepljivanja uspješnih strategija (Siegler, 2000). Prema modelu asocijativne snage koji opisuju Siegler i Jenkins (1989), strategije se pohranjuju u pamćenju kao pravila, i imaju pridruženu vrijednost koja određuje njihovu snagu na temelju prošlih uspješnih primjena, a koja određuje i vjerojatnost pojavljivanja te strategije u sljedećim susretima sa zadatkom. Prema tome modelu, nije potrebna svjesnost ili refleksija o strategijama da bi se one mijenjale. Međutim, ovakav model ne može objasniti dugotrajno paralelno postojanje

strategija različite valjanosti, pa se zaključuje da je za objašnjenje promjena u korištenju strategija ključna meta razina, odnosno razina koja izabire, prati i vrednuje strategije koje se koriste (Kuhn, 1997, 1999, 2001b, 2002a, 2002b).

Kuhn (2002b), raspravljajući o mehanizmima koji dovode do promjena, navodi da se «*u procesu promjena događa više od onog što se opaža na razini izvedbe*» (str. 116). Za objašnjenje procesa promjena, autorica naglašava važnost meta razine, odnosno razine na kojoj se strategije biraju tako da odgovaraju ciljevima zadatka, i na kojoj se upravlja i nadgleda njihovo korištenje. Razvoj znanstvenog razmišljanja se upravo sastoji u povećanju metakognitivne svjesnosti i kontrole nad procesom koordinacije teorije i nalaza u procesu stjecanja znanja (Kuhn i Pearsall, 2000; Kuhn, 2001b, 2002a).

Mikrorazvojna istraživanja pokazuju da pri istraživačkom učenju, osim na razini izvedbe, promjene se događaju i na meta razini - jača metakognitivno znanje o cilju zadatka, kao i metastrateško razumijevanje potrebe kontrole varijabli (Kuhn i Pearsall, 1998; Kuhn, 2002b).

Kuhn i Pearsall (1998) upravo razlikuju te dvije komponente meta razine: razumijevanje cilja zadatka (engl. *metatask understanding/ knowing*) i metastrateško razumijevanje (engl. *metastrategic understanding/ knowing*). Razumijevanje cilja zadatka se odnosi na razumijevanje prirode i zahtjeva zadatka, odnosno prepoznavanje toga da je cilj zadatka istraživačkog učenja određivanje učinaka pojedinih varijabli, a metastrateško razumijevanje se odnosi na svjesnost i razumijevanje strategija dostupnih u repertoaru strategija koje se mogu primijeniti na zadatku kako bi se ostvario cilj. Za učinkovito funkcioniranje na meta razini ključna je koordinacija tih dvaju komponenti (Kuhn i Pearsall, 1998). Obje su komponente potrebne za učinkovito strateško djelovanje, iako i potpuno razumijevanje cilja zadatka i razumijevanje strategija ne osigurava nužno uspješno strateško djelovanje<sup>6</sup> (Kuhn i Pearsall, 1998).

---

<sup>6</sup> Metakognitivno znanje o cilju i strategijama rada na zadatku Kuhn smatra proceduralnim meta znanjem (Kuhn, 2001, 2002b), koje, za razliku od deklarativnog metakognitivnog znanja, djeluje pri 'stvarnom' odabiru i regulaciji korištenja istraživačkih strategija. Kako bi naglasila proceduralnu prirodu tih koncepata, Kuhn koristi pojam 'knowing' umjesto 'knowledge'. Može se, međutim, tvrditi da se u istraživanju Kuhn i Pearsall (1998) te dvije komponente meta razine ispituju kao deklarativno znanje, budući da se od ispitanika traži verbalizacija o tome što je cilj i kako treba raditi na zadatku istraživačkog učenja, čime se ispituje što učenik podrazumijeva pod poželjnim strategijama rada na zadatku. Imajući to na umu, očekivan je nalaz koji kaže da najviša razina iskazanog meta znanja nije nužno povezana s uspješnim strateškim djelovanjem. Deklarativnim metakognitivnim znanjem Kuhn (2001, 2002b) smatra meta znanje vezano uz fazu donošenja zaključaka, koje predstavlja razumijevanje izvora znanja i načina dolaska do znanja. Prema Kuhn (2001, 2002b) razlika između deklarativnog i proceduralnog meta znanja nalazi se u tome što proceduralno meta znanje generira povratnu informaciju kroz djelovanje, a deklarativno ne.

Meta znanje je preduvjet uspješnog strateškog djelovanja. Da bi se koristile prikladne strategije rada na zadatku učenik imati dovoljno razvijeno meta razumijevanje koje mu omogućuje da prepozna primjenjivost tih strategija za postizanje cilja definiranog zadatkom (Kuhn i Pearsall, 1998). Meta razina upravlja primjenom strategija, a povratne informacije o primjeni strategija informiraju meta razinu. Kad učenici biraju strategiju koju će primijeniti na zadatku, čine to s razumijevanjem (točnim ili netočnim) da će takva strategija dovesti do cilja. Povratne informacije, nastale kao posljedica strateškog djelovanja, povećavaju metakognitivnu svjesnost o cilju zadatka i usklađenosti pojedinih strategija s postizanjem tog cilja, kao i metastrateško znanje o korisnosti, mogućnostima i ograničenjima primijenjenih strategija. Ta povećana svjesnost na meta razini mijenja proces odabira strategija i postepeno dovodi do promjena u raspodjeli korištenja strategija koja se opaža na razini izvedbe. Promjene u korištenju strategija, odnosno uvježbavanje strateškog djelovanja, opet jačaju meta razinu, pa se stvara kontinuiran ciklus u kojem meta razina istovremeno i upravlja razinom izvedbe i biva njome promijenjena (Kuhn, 2001b, 2002b). Promjene na razini izvedbe su, stoga, određene i posredovane meta razinom.

Kuhn i Pearsall (1998) razmatraju smjer uzročno - posljedičnih veza strateškog i metastrateškog djelovanja i zaključuju da vjerojatno postoje višestruki putovi utjecaja između strateške i metastrateške razine. Strateška razina može utjecati na meta razinu, tako što uspjeh u primjeni strategija vodi većem metastrateškom razumijevanju i shvaćanju vrijednosti i upotrebljivosti valjanih strategija. Isto tako, neuspješno strateško djelovanje jača metastratešku razinu, jer vodi metastrateškoj potrazi za novim pristupima. Ipak, autorice navode mogućnost i obrnutog djelovanja, te pretpostavljaju utjecaj meta razine na stratešku razinu, npr. kad nemogućnost postizanja onoga što učenik zamišlja kao cilj zadatka vodi do varijacija u korištenju strategija prema valjanijim strategijama, ili kad novo stečeni metastrateški uvid (bolje razumijevanje cilja zadatka i veća svijest o postojanju određenih strategija) predstavlja poticaj za odabir drugačijih i boljih istraživačkih strategija koje će se primijeniti u odgovaranju na zahtjeve zadatka (Kuhn i Pearsall, 1998; Kuhn, 2001b, 2002a, 2002b, 2005).

Iako je meta razinu moguće posredno jačati putem povratnih informacija sa strateške razine, to nije najučinkovitiji i najbolji put (Kuhn, 2001b, 2002b). Meta razina se ne može razvijati kvalitetno niti kad se učenike usko poučava korištenju neke strategije (npr. strategije kontrole varijabli). Poteškoća s direktnim poučavanjem strategija je u tome što

ono ne mijenja mentalni model kauzalnosti i ne omogućuje razvoj razumijevanja na meta razini i transfer na nove situacije učenja (Kuhn i sur., 2000; Kuhn, 2001b; Keselman i Kuhn, 2002). Osim toga, u situacijama ponavljanog rada na zadacima istraživačkog učenja promjene na meta razini ne događaju se kod svih učenika. Pretpostavlja se da je kod nekih učenika meta razina previše slaba da bi mogla iskoristiti povratnu informaciju koja dolazi s razine izvedbe (Kuhn, 2001b). Kako bi došlo do transfera u nove situacije učenja i kako bi do promjene došlo kod svih učenika, potrebno je direktno jačati meta razinu, odnosno učiti učenike ne samo koje strategije koristiti, kad i kako ih izvesti, nego im i pomoći razumjeti zašto su neke strategije učinkovite, a druge ne. Tu se radi o jačanju metastrateškog znanja, odnosno sposobnosti reflektiranja i upravljanja strateškim znanjem, te povezivanja s ciljem zadatka (Kuhn i Dean, 2005). Meta razina se može potaknuti traženjem od učenika da reflektiraju ili samoobjašnjavaju različite faze svog rada (Lin i Lehman, 1990; Keselman, 2003), ili da vrednuju rad drugih učenika na zadatku (Pearsall, 1999), vježbanjem meta razine kroz vrednovanje različitih strategija koje se mogu primijeniti na zadatku (Kuhn i sur., 2000), direktnim podučavanjem metastrateškog znanja (korištenjem eksplicitne poduke o tome zašto, kako, kada koristiti strategiju kontrole varijabli u kombinaciji s iskustvenim učenjem) (Zohar i Peled, 2008; Zohar i Ben David, 2008), kao i eksternalizacijom meta razumijevanja putem verbalizacija tijekom kolaborativnog rada u parovima (Andersen, 1998).

#### **2.4. Istraživačko učenje i motivacijski i emocionalni aspekti učenja: implikacije za istraživanje**

Pregled literature s područja znanstvenog razmišljanja predstavio je istraživačko učenje kao složen proces učenja koji zahtijeva koordinaciju različitih kognitivnih i metakognitivnih procesa, te uključuje međudjelovanje nespecifičnih istraživačkih vještina i strategija i konceptualnog razumijevanja u određenom znanstvenom području. Prikazana istraživanja, posebice ona u sklopu integrativnog pristupa, u kojima učenici sudjeluju u svim fazama istraživačkog rada, ukazuju da učenici u predadolescentskoj i adolescentskoj dobi pokazuju nedostatnu razvijenost vještina potrebnih za valjano eksperimentiranje i zaključivanje u multivarijatnom kauzalnom kontekstu, ali sugeriraju i njihovu razvojnu spremnost za jačanje i usavršavanje tih vještina, ukoliko im se osiguraju odgovarajuća obrazovna iskustva.



I dok navedena istraživanja osiguravaju važne uvide o različitim kognitivnim i metakognitivnim vještinama i strategijama uključenim u istraživačko učenje, koji imaju i svoje praktične implikacije, ova istraživanja nedostavno zahvaćaju cjelovitost procesa učenja. Spomenuta istraživanja sasvim zanemaruju motivacijske i emocionalne aspekte učenja, kao i elemente neposrednog praćenja kognitivnih procesa kroz metakognitivni doživljaj, te ne uzimaju dovoljno u obzir da je učenje cilju orijentiran proces, pri kojem se ciljevi istraživača (ili nastavnika) ne moraju podudarati s ciljevima učenika. Istraživanja istraživačkog učenja gotovo uopće ne propituju utjecaj koji na započinjanje i održavanje aktivnosti učenja, kao i na odabir i izvođenje pojedinih istraživačkih vještina i strategija mogu imati, primjerice, interes učenika za zadatak i predmet istraživanja, njihova procjena korisnosti zadatka i istraživačkog učenja, procjena samoeфикаsnosti u rješavanju zadatka, procjena težine zadatka, procjena uloženog truda i slično, kao ni to kakav povratni učinak ima (ne)uspjeh u istraživačkom procesu na daljnju motivaciju učenika za istraživačko učenje i učenje znanstvenih koncepata općenito. Opravdano je, međutim, pretpostaviti da motivacija tijekom rada na zadatku istraživačkog učenja, kao i metakognitivni doživljaj, imaju utjecaj na procese i ishode istraživačkog učenja, budući da se za uspješan rad na kompleksnom zadatku kakav je zadatak istraživačkog učenja potreban aktivan, sustavan i refleksivan pristup u eksperimentiranju i zaključivanju, koji zahtijeva usmjeravanje i održavanje pažnje, ulaganje truda, samoregulaciju, ustrajnost.

Istraživanje predstavljeno u ovom radu stoga stavlja istraživačko učenje u širi okvir samoregulirajućeg učenja, te pored kognitivnih i metakognitivnih vještina i strategija, ispituje motivacijske, metakognitivne i emocionalne reakcije na zadatak i rad na njemu. Istraživanje se usmjerava na ispitivanje međuodnosa tih različitih sastavnica procesa istraživačkog učenja, kao i na utvrđivanje njihovog utjecaja na rezultate učenja. Pretpostavlja se da takvo cjelovitije zahvaćanje procesa uključenih u istraživačko učenje može pridonijeti boljem razumijevanju rezultata koje postižu učenici kad znanstveno razmišljaju i istraživački uče.

U nastavku pregleda literature pobliže je objašnjen koncept samoregulirajućeg učenja, te njegovih pojedinih sastavnica. Na kraju je istraživačko učenje razloženo na elemente koji ga čine samoregulirajućim učenjem.

## II. DIO: PREGLED PODRUČJA ISTRAŽIVANJA ISTRAŽIVAČKOG UČENJA KAO SAMOREGULIRAJUĆEG UČENJA

### 2.5. Samoregulirajuće učenje: konceptualno određenje

U literaturi o samoregulirajućem učenju moguće je naići na mnoštvo različitih teorijskih konceptualizacija. Među njima, najdetaljnije su elaborirane i najutjecajnije u području istraživanja samoregulirajućeg učenja u školskom kontekstu sociokognitivistička teorija Zimmermana i Schunka (Zimmerman i Schunk, 1989; Schunk i Zimmerman, 1998; Zimmerman, B.J. 1990, 2005), Pintrichev konceptualni okvir za procjenu motivacije i samoregulirajućeg učenja (Pintrich, 2004, 2005), Winneov četverofazni model samoregulirajućeg učenja (Winne, 1995, 1996; Winne i Hadwin, 1998; Winne i sur., 2002), Butleričin model samoregulirajućeg učenja uronjenog u kontekst (Butler i Winne, 1995; Butler, 1996, 1997; Butler i Cartier, 2005) i Boekaertsin model prilagodljivog učenja (Boekaerts, 1997, 1999; Boekaerts i Niemivirta, 2005).

Ti različiti modeli na ponešto drugačiji način definiraju samoregulirajuće učenje i stavljaju različit naglasak na pojedine njegove sastavnice ili faze, ali međusobno imaju mnogo zajedničkih elemenata ili pretpostavki (Puustinen i Pulkkinen, 2001; Zeidner, Boekaerts i Pintrich, 2005). Naime, svi modeli zauzimaju konstruktivistički pristup učenju, koji podrazumijeva da učenici pri učenju aktivno konstruiraju značenja, ciljeve i strategije na temelju informacija iz vanjskog i unutarnjeg svijeta, povezujući nove spoznaje s postojećim znanjima, mentalnim strukturama i vjerovanja (Pintrich, 2004). Nadalje, različiti modeli dijele shvaćanje da učenici imaju kontrolu nad vlastitim učenjem, odnosno da svi učenici, barem u nekom stupnju, mogu pratiti, kontrolirati i regulirati svoje kognicije, motivaciju, ponašanje, kao i određene elemente okoline (Pintrich, 2004).

Uz navedeno, različitim modelima samoregulacije zajedničko je viđenje da učenici postavljaju vlastite ciljeve učenja i onda upravljaju, prate, reguliraju i kontroliraju svoje kognicije, motivaciju i ponašanje kako bi ostvarili te ciljeve (Wolters, Pintrich, Karabenick, 2003). Učenici uspoređuju procese i rezultate svojih aktivnosti s ciljevima ili standardima koje su postavili, kako bi odredili treba li nastaviti s učenjem ili ga mijenjati. Povratna sprega koja služi za smanjivanje razlika između opaženog i poželjnog stanja sastavni je dio samoregulacije učenja (Zeidner i sur., 2005).

Definirajući samoregulirajuće učenje kroz ove elemente, podrazumijeva se da je ono prvenstveno usmjeren i svjestan proces, kao i da se jasno razlikuje od učenja koje je regulirano izvana (Rheinberg i sur., 2005; Boekaerts i Cascallar, 2006). Pokušaji kontroliranja ili reguliranja vlastitog učenja mogu se smatrati samoreguliranimi upravo onda kad je osoba usmjerena na kontrolu i reguliranje vlastitih kognicija, motivacija i ponašanja, pri čemu kontekstualni čimbenici i druge osobe mogu olakšati ili ograničiti učenika u njegovim pokušajima samoregulacije (Wolters i sur., 2003).

Nadalje, svi modeli predstavljaju samoregulirajuće učenje kao složen konstrukt, koji uključuje različite kognitivne, metakognitivne, motivacijske i afektivne procese i mehanizme kojima učenici reguliraju svoje učenje (Zeidner i sur, 2005), te postuliraju da samoregulacija kognicija, motivacije i ponašanja posreduje u odnosu između učenika, konteksta i postignutih rezultata učenja (Pintrich, 2004). Postojeći modeli se ponešto razlikuju po tome koje elemente procesa samoregulacije naglašavaju (Puustinen i Pulkkinen, 2001). Neki autori (Pintrich, Zimmerman, Boekaerts i Butler) ističu da je samoregulirajuće učenje cilju usmjerenu aktivnost kojom učenik aktivno upravlja koristeći kognitivne, motivacijske, emocionalne i socijalne (kontekstualne) resurse i mehanizme. S druge strane, Winne u definiciju samoregulirajućeg učenja ne uključuje usmjerenost prema cilju, već ga definira kao ono koje je metakognitivno vođeno i usmjereno biranju i prilagođavanju korištenja kognitivnih strategija i taktika u rješavanju zadataka (Winne, 1995, 1996; Winne i Hadwin, 1998). Ipak, razrada Winneovog modela jasno pokazuje da autor podrazumijeva da samoregulacija ne uključuje samo kognitivne i metakognitivne procese, kao i to da smatra da su učenici barem dijelom intrinzično motivirani i usmjereni prema ciljevima (Winne i Hadwin, 1998; Winne i sur., 2002). U Winneovom modelu je jasno da ciljevi, koje učenici postavljaju prije faze korištenja taktika i strategija, predstavljaju standarde s kojima se uspoređuju procesi i rezultati rada na zadatku.

Konačno, uz sličnosti definicija i uključenih sastavnica procesa samoregulacije, sličnost među navedenim modelima samoregulirajućeg učenja očituje se i u tome što opisuju samoregulirajuće učenje kao ciklički proces, odnosno proces koji se odvija u nekoliko faza, koje nisu nužno linearno i sekvencijalno strukturirane (Azevedo, 2009). Unatoč ponešto različitom broju i nazivlju faza, različiti modeli pretpostavljaju postojanje pripremne, operativne i kontrolne faze u procesu samoregulacije. U pripremnoj, orijentacijskoj fazi učenik definira, procjenjuje, interpretira zadatak, postavlja ciljeve i planira aktivnosti za ostvarivanje tih ciljeva. U operativnoj fazi učenik primjenjuje strategije rada na zadatku, a

metakognitivno prati procese i učinke vlastitog rada, dok se u kontrolnoj fazi na temelju praćenja procesa i rezultata rada provodi vrednovanje i prilagodba pristupa, znanja i vjerovanja, ovisno o utvrđenoj usklađenosti s ciljevima učenja.

Modeli se, dakako, ponešto razlikuju u tome koji koncepti čine osnovicu pojedine faze, kao i u naglasku koji se stavlja na njih ili njihove međusobne odnose (Puustinen i Pulkkinen, 2001). U nekim modelima izrazito je istaknuta važnost okruženja u kojem se odvija učenje pa Butler govori o slojevima konteksta koji predstavljaju okvir u kojem se odvija učenje (Butler i Cartier, 2005), a Pintrich (2004), slično kao i Zimmerman i Schunk (1989), regulaciju konteksta smješta ravnomjerno regulaciji kognicije, motivacijskih i afektivnih procesa i ponašanja. U modelima koji počivaju na socio-kognitivničkoj perspektivi velika uloga pripada i samopercepcijama postignuća, procjeni samoeфикаsnosti i motivacijskim konstruktima općenito. U Boekaertsinom modelu prilagodljivog učenja (Boekaerts i Niemivirta, 2005) najveći se dio pažnje, osim na interpretaciju i procjenu situacije, stavlja na ciljeve, odnosno na njihovo postavljanje i transformiranje u aktivnosti, dok se kasnije faze u procesu samoregulacije (operativna i kontrolna) opisuju mnogo površnije. S druge strane, naglasak Winneovog modela je upravo na procesima koje Boekaerts obrađuje manje detaljno, pa tako najveću važnost Winne pridaje procesima metakognitivnog praćenja koji stvaraju unutarnje povratne informacije i omogućuju započinjanje kontrolnih procesa tijekom svih faza samoregulirajućeg učenja (Winne i Hadwin, 1998; Winne i sur., 2002). Za razliku od toga, drugi navedeni modeli (Pintrich, Zimmerman, Boekaerts) pretpostavljaju da se procesi metakognitivnog praćenja odvijaju tijekom operativne faze, a povratne informacije proizašle iz tog praćenja djeluju samo u zadnjoj fazi samoregulirajućeg učenja (Puustinen i Pulkkinen, 2001).

Iz prikaza zajedničkih elemenata različitih modela samoregulirajućeg učenja, moguće je zaključiti da autori tih modela dijele mnogo ideja o tome što samoregulirajuće učenje jest i kako se samoregulacija odvija u situacijama učenja. Ne postoji, međutim, prihvaćena zajednička definicija samoregulirajućeg učenja, kao ni definicija srodnih konstrukata samoregulacije, metakognicije (Dinsmore, Alexander i Loughlin, 2008), samokontrole, samoupravljanja (Zeidner i sur., 2005), te problemskog učenja i samoupravljanog učenja (Loyens, Magda i Rikers, 2008). Iako postojanje višestrukih definicija i operacionalizacija istog pojma nije neuobičajeno u psihologiji obrazovanja, stanje se može smatrati problematičnim, imajući na umu da definiranje procesa utječe na to kako ih mjerimo i kako interpretiramo rezultate istraživanja (Schunk, 2008). Autor stoga poziva na formuliranje

jasne i precizne definicije samoregulirajućeg učenja, te upućuje istraživače na potrebu identificiranja relevantnih teorijskih postavki iz kojih pojedine definicije proizlaze i usklađivanja mjernih postupaka s tim definicijama i postavkama. Jednako je važno sustavno razvijanje taksonomija različitih konstrukata iz područja samoregulacije učenja (Zeidner i sur., 2005; Azevedo, 2009). O nekim od tih konstrukata, metakogniciji i motivaciji, bit će riječi u sljedećim poglavljima.

## **2.6. Sastavnice samoregulirajućeg učenja**

U prijašnjem je poglavlju istaknuto da različiti modeli samoregulirajućeg učenja ističu složenost tog konstrukta i interakcijske odnose kognitivnih, metakognitivnih, motivacijskih, emocionalnih i kontekstualnih čimbenika samoregulacijskog procesa.

Samoregulirani učenici su okarakterizirani kao metakognitivni, motivirani za učenje i strateški (Winne i Perry, 2005), iako se podrazumijeva da svi učenici reguliraju vlastito učenje, ali ne uvijek podjednako uspješno (Winne, 1995). Stoga se smatra da su učenici samoregulirani u stupnju u kojem su metakognitivno, motivacijski i ponašajno aktivni sudionici procesa vlastitog učenja (Zimmerman i Schunk, 1989). Pritom, podrazumijeva se da ne postoji samo jedan skup kognitivnih, metakognitivnih, motivacijskih i bihevioralnih strategija koje predstavljaju prikladan način rada na nekom zadatku, već su različite vrste samoregulirajućih aktivnosti više ili manje prikladne za različite zadatke, različite situacije učenja i različite učenike (Kaplan, 2008).

U području samoregulirajućeg učenja znatan je broj radova posvećen teorijskim razmatranjima i istraživanjima pojedinih sastavnica (dijelova) tog procesa, pa se istraživači često usmjeravaju na ispitivanje (pojedinih) motivacijskih ili metakognitivnih čimbenika i njihovog utjecaja na procese i rezultate učenja. Postoji znatan dio istraživanja koji ne uzimaju u obzir niti ishode učenja, već izolirano promatraju odnose drugih čimbenika (Winters, Greene i Costich, 2008; Schunk, 2008). Vrlo je malo istraživanja koje samoregulirajuće učenje ispituju u njegovoj cjelovitosti (Winters i sur., 2008).

U nastavku su pobliže opisani koncepti metakognicije i motivacije kao važnih sastavnica samoregulirajućeg učenja, te su predstavljeni rezultati nekih istraživanja koja su se bavila motivacijskim ili metakognitivnim čimbenicima istraživačkog učenja, koji su predmet ovog rada.

### ***2.6.1. Metakognicija i samoregulirajuće učenje***

Pod metakognicijom se izvorno podrazumijeva znanje i regulacija kognitivnih aktivnosti tijekom procesa učenja (Brown, 1978; Flavell, 1979). Do danas, međutim, koncept nije sasvim teorijski određen niti razgraničen od drugih koncepata s kojima se povezuje, pa se u obrazovnoj literaturi često izmjenjuje s pojmovima samoregulirajućeg učenja i samoregulacije (Dinsmore i sur., 2008). Neki autori izjednačavaju metakogniciju s metakognitivnim vještinama, ili čak drže samoregulaciju dijelom metakognicije, dok drugi autori samoregulirajuće učenje smatraju konceptom koji se nalazi iznad i uključuje, osim metakognicije, i motivacijske i emocionalne procese (Veenman, Van Hout-Wolters i Afflerbach, 2006).

Bez obzira na odnose s drugim konstruktima, određenje metakognicije kao kognicije o kogniciji nije sporno za većinu autora. Pod metakognicijom se podrazumijeva misaoni proces više razine koji aktivno nadgleda i upravlja kognitivnim sustavom, dok je istovremeno njegov dio. Kognitivne i metakognitivne procese teško je razdijeliti u mjerenju (Veenman i sur., 2006). Metakognicija često nije eksplicitno verbalizirana tijekom rada na zadatku pa se o njoj zaključuje na temelju kognitivnih aktivnosti. Dok u svakoj metakognitivnoj aktivnosti postoje kognitivni procesi, metakognicija može biti prisutna tijekom pojedine kognitivne radnje, ali ne mora uvijek biti vidljiva.

Flavell (1979) navodi da se metakognicija i kognicija razlikuju u sadržaju i funkciji, ali su slični u formi i kvaliteti. Sadržaji metakognicije su znanja, vještine i informacije o kognicijama, dok su kognicije o objektima iz stvarnog svijeta i mentalnim slikama. Dakle, izvor metakognicije nije neposredna vanjska realnost osobe, već unutarnje, mentalne reprezentacije tog realiteta. Funkcija kognicije je rješavanje problema i ostvarivanje kognitivnih ciljeva, a funkcija metakognicije reguliranje kognitivnih operacija tijekom rješavanja problema i izvršavanja zadataka. Kognitivna znanja i vještine su potrebne za izvršavanje zadatka, a metakognicija je potrebna za razumijevanje toga kako je zadatak izvršen (Schraw, 2002). Npr. provjeravanje toga je li rješenje zadatka ispravno kognitivna je aktivnost, ali je namjera provjere rezultata metakognitivna po svojoj prirodi.

Opisujući poziciju i funkcije metakognicije unutar kognitivnog sustava, Nelson (1996) prikazuje jednostavan model u kojem razlikuje a) razinu objekta na kojoj se odvijaju kognitivne aktivnosti, i b) meta razinu koja rukovodi razinom objekta. Meta razina je povezana s razinom objekta kroz funkcije praćenja i kontrole. Te se funkcije mogu shvatiti

osnovnim funkcijama metakognicije. Kroz proces praćenja, informacije o stanju na razini objekta dolaze do meta razine, a meta razina šalje instrukcije i mijenja razinu objekta kroz procese kontrole. Praćenje kognitivnih aktivnosti, dakle, pruža informacije koje kontrolna funkcija koristi za upravljanje i reguliranje kognicija.

Pritom, dvije osnovne manifestacije metakognitivne funkcije praćenja su metakognitivni doživljaj i metakognitivno znanje, a manifestacija funkcije regulacije i kontrole kognitivnih procesa su metakognitivne vještine ili strategije (Efklides, 2001, 2006b).

U tablici 2 prikazane su te osnovne sastavnice metakognicije, kao i njihovi elementi.

*Tablica 2*

Sastavnice metakognicije i njezine manifestacije kroz funkcije praćenja i kontrole (preuzeto od Efklides, 2006b)

FUNKCIJA PRAĆENJA KOGNITIVNIH AKTIVNOSTI		FUNKCIJA KONTROLE KOGNITIVNIH AKTIVNOSTI
Metakognitivno znanje	Metakognitivni doživljaj	Metakognitivne vještine
<p><b>Ideje, vjerovanja, teorije o:</b></p> <ul style="list-style-type: none"> <li>- sebi</li> <li>- zadatku</li> <li>- strategijama</li> <li>- ciljevima</li> <li>- kognitivnim funkcijama</li> <li>- valjanosti znanja</li> <li>- teorija uma</li> </ul>	<p><b>Metakognitivni osjećaji</b></p> <ul style="list-style-type: none"> <li>- osjećaj poznatosti</li> <li>- osjećaj težine</li> <li>- osjećaj poznavanja</li> <li>- osjećaj uvjerenosti</li> <li>- osjećaj zadovoljstva</li> </ul> <p><b>Procjene i prosudbe</b></p> <ul style="list-style-type: none"> <li>- procjena učenja</li> <li>- informacija o izvoru pamćenja</li> <li>- procjena uloženog napora</li> <li>- procjena vremena</li> </ul> <p><b>Specifična znanja vezana uz zadatak</b></p> <ul style="list-style-type: none"> <li>- karakteristike zadatka</li> <li>- zahtjevi zadatka</li> </ul>	<p><b>Svjesne i usmjerene aktivnosti i korištenje strategija za:</b></p> <ul style="list-style-type: none"> <li>- alokaciju truda</li> <li>- alokaciju vremena</li> <li>- orijentaciju i praćenje zahtjeva zadatka</li> <li>- planiranje</li> <li>- provjeru i regulaciju kognitivnog procesiranja</li> <li>- vrednovanje rezultata procesiranja</li> </ul>

### *Metakognitivno znanje*

Metakognitivno znanje je deklarativno znanje o kognicijama koje je pohranjeno u dugotrajnom pamćenju (Flavell, 1979). Ono uključuje implicitne ili eksplicitne ideje, vjerovanja, teorije ili znanje o strategijama koje mogu biti korištene u pojedinim zadacima, znanje o uvjetima pod kojima se mogu koristiti strategije, znanje o učinkovitosti strategija, znanje o težini i zahtjevima zadataka, te znanje o sebi i drugima kao kognitivnim procesorima (Pintrich, 2002). Osim znanja o strategijama, zadacima i sebi, metakognitivno znanje uključuje znanje o različitim kognitivnim funkcijama i procesima (npr. što je i kako funkcionira pažnja, pamćenje itd), kao i svjesnost i znanje o vlastitim kognicijama i učenju.

U kontekstu istraživačkog učenja, ključni elementi metakognitivnog znanja su metakognitivno znanje o cilju i zahtjevima zadatka i metastrateško znanje o potrebi korištenja strategije kontrole varijabli (Kuhn i Pearsall, 1998; Kuhn, 1999, 2000, 2002a), te epistemološko razumijevanje izvora znanja (Kuhn, Cheney i Weinstock, 2000, Kuhn 2002a; Kuhn i Park, 2005; Kuhn i Franklin, 2006), o čemu je detaljnije bilo riječi u prethodnim poglavljima. Međutim, za istraživačko učenje mogu biti važna i druga metakognitivna znanja o kognitivnim aktivnostima koja čine sklop viših kognitivnih procesa, na primjer znanja o klasificiranju, uspostavljanju i analiziranju kauzalnih veza, formuliranju istraživačkih pitanja, testiranju hipoteza, donošenju valjanih zaključaka, formuliranju argumenata itd. (Zohar i Peled, 2008; Zohar i David, 2008).

Metakognitivno znanje može biti prizvano iz dugoročnog pamćenja kao rezultat svrhovite i svjesne potrage, a može biti i aktivirano nenamjerno ili automatski na temelju znakova prisutnih u situaciji učenja. Aktivacija metakognitivnog znanje ne vodi nužno prikladnom ponašajnom (strateškom) odgovoru na zadatak – za to je nužno proceduralno znanje, odnosno postojanje metakognitivnih vještina (Veenman i sur., 2004). Moguće je, na primjer, da učenik zna da je u zadatku istraživačkog učenja potrebno koristiti strategiju kontrole varijabli, ali da to ipak ne provodi. Osim toga, metakognitivno znanje može biti i netočno, a i nije uvijek eksplicitno.

Važnost metakognitivnog znanja očituje se u tome što ono usmjerava interpretaciju situacije učenja i zahtjeva zadatka (Efklides, 2006b), a predstavlja izvor iz kojeg učenici crpe informacije o tome koje strategije primijeniti u kontroli i regulaciji učenja u pojedinom zadatku, u situaciji zakazivanja automatskog kognitivnog procesiranja (Efklides, 2009). Metakognitivni doživljaj uzima u obzir podatke koji čine metakognitivno znanje, a metakognitivno znanje se neprestano obogaćuje i diferencira integriranjem informacija nastalih kroz praćenje kognicije na svjesnoj razini (praćenje vlastitih doživljaja i ponašanja i opažanje njihovih ishoda u različitim situacijama učenja), kroz svjesnost metakognitivnog doživljaja, i kroz komunikaciju s drugima (Efklides, 2008).

### *Metakognitivni doživljaj*

Metakognitivni doživljaj (*engl.* metacognitive experience) predstavlja subjektivno iskustvo koje prati kognitivnu aktivnost (Efklides, 2001), odnosno metakogniciju prisutnu u radnom pamćenju (Efklides, 2002). Radi se o trenutnoj svjesnosti osobe u trenutku dok obavlja zadatak (Flavell, 1979). To subjektivno iskustvo čine misli, procjene i osjećaji koji su



prisutni kad osoba procesira zadatak, a usmjereni su na specifične aspekte kognitivnog procesiranja pojedinog zadatka (Efklides, 2001).

Važnost metakognitivnog doživljaja nalazi se u obavljanju metakognitivne funkcije praćenja i posredovanju između učenika i zadatka. Metakognitivni doživljaj informira učenike o napredovanju ili zastoju u radu na zadatku, te prati ishode procesiranja. Tijekom procesiranja zadatka, metakognitivni doživljaj se mijenja ili ostaje nepromijenjen, ovisno o tome kako učenik percipira fluentnost procesiranja (Efklides, 2006a). Metakognitivni doživljaj predstavlja osnovu za donošenje kontrolnih odluka tijekom procesiranja zadatka, npr. za započinjanje, završavanje ili ustrajanje na nekoj aktivnosti, što ga čini ključnim za samoregulaciju učenja. Kontrola i regulacija kognitivnih aktivnosti, međutim, nije moguća bez posjedovanja metakognitivnog znanja o dostupnim i učinkovitim strategijama, kao i bez aktiviranja proceduralnog znanja (metastrateških vještina).

Metakognitivni doživljaj se razlikuje od percepcije ili analize zahtjeva zadatka, jer može biti temeljen na neanalitičkim, heurističkim, pa i nesvjesnim inferencijalnim procesima (Efklides, 2001, 2006b). Osim toga, metakognitivni doživljaj ne prati samo karakteristike zadatka, već odražava i učenikove reakcije i ciljeve u odnosu na zadatak (Efklides, 2001). Istraživanja Efklides i suradnika (1999, 2000; prema Efklides, 2001) pokazuju da se metakognitivni doživljaj temelji na informacijama iz radnog pamćenja, ali i na interpretacijama proizašlima iz motivacijske orijentacije učenika, njihovog akademskog samopoimanja, trenutnog raspoloženja, emocionalnog stanja, metakognitivnog znanja o sebi. Metakognitivni doživljaj ovisi i o osobinama situacije učenja (složenosti zadatka, prijašnjem iskustvu na zadatku), ali zbog subjektivne prirode uvjetuje da npr. neki objektivno težak zadatak bude doživljen kao subjektivno lagan, ako učenik ima iskustvo rada na takvom zadatku (Efklides, 2006a).

Osim utjecaja motivacijskih i emocionalnih čimbenika na formiranje metakognitivnog doživljaja, istraživanja Efklides i suradnika su pokazala i povratni učinak metakognitivnog doživljaja na motivacijske procjene učenika, samopoimanje i kauzalne atribucije koje prate rješavanje problema (Efklides, 2001; Metallidou i Efklides, 2001).

Po Efklides (2001), metakognitivni doživljaj čine metakognitivni osjećaji, metakognitivne procjene ili prosudbe i specifična znanja vezana uz zadatak. U širem smislu, i afektivna iskustva koja se pojavljuju u vezi sa zadatkom npr. interes za zadatak, sviđanje zadatka,

razočarenje i slično mogu se smatrati dijelom metakognitivnog doživljaja jer se pojavljuju u isto vrijeme (Efklides, 2006a). I drugi autori govore o preklapanju metakognitivnih i motivacijskih koncepata, te navode da se ponekad varijable koje se koriste za mjerenje motivacije i metakognicije definiraju i operacionaliziraju na isti način npr. procjena rezultata učenja (Weinert, 1984; prema Vollmeyer i Rheinberg, 1999).

*Metakognitivni osjećaji* imaju dvojni, kognitivni i afektivni, karakter (Efklides, 2006b). Po svojoj prirodi, oni su metakognitivni, jer su produkt praćenja tijekom kognitivnog procesiranja zadatka, ali, poput emocija, imaju kvalitetu ugodnog ili neugodnog (Efklides, 2001). Prisustvo osjećaja u metakognitivnom događaju podrazumijeva da metakognitivni doživljaj ima osobni karakter, karakter osobnog subjektivnog iskustva (Efklides, 2001). Osim što informiraju učenike o kognitivnom procesiranju zadatka, te o samopoimanju i samoefikasnosti (Efklides, 2009), metakognitivni osjećaji predstavljaju ulazne informacije za donošenje kontrolnih odluka i druge kognitivne procese koji pretpostavljaju refleksivnost. U iskustvu učenika javljaju se u obliku osjećaja težine, osjećaja poznatosti zadatka, osjećaja zadovoljstva, osjećaja uvjerenosti u točnost rješenja itd.

Za razliku od metakognitivnih osjećaja, *metakognitivne procjene ili prosudbe* nemaju afektivni karakter, već su isključivo kognitivne (Efklides, 2001), a odnose se na procjene koje učenici daju o kvalitetama ili osobinama vlastitih kognicija ili kognitivnog funkcioniranja na zadatku (Efklides, 2002). Ove procjene mogu nastati i kao produkti analitičkih i neanalitičkih procesa (Efklides, 2008). U ovu kategoriju spadaju procjena naučenog, procjena izvora pamćenja, procjena zahtjevnosti kognitivnog procesiranja, procjena potrebe ulaganja truda, procjena vremena potrebnog za rješavanje zadatka, procjena uloženog truda, procjena točnosti rješenja itd.

Iako su međusobno povezani i tvore određene povezane strukture, različiti metakognitivni osjećaji i procjene nose ponešto drugačije informacije o osobinama kognitivnog procesiranja (Efklides, 2002). Na primjer, procjena točnosti rješenja se odnosi na kvalitetu odgovora (točno – netočno), dok osjećaj uvjerenosti prati kako je učenik došao do rješenja (bez zastoja ili s prekidima). Nadalje, osjećaj težine se može predvidjeti na temelju negativnog raspoloženja, a procjena uloženog truda na temelju pozitivnog raspoloženja (Efklides i Petkaki, 2005).

Osim što metakognitivni osjećaji i procjene prate ponešto različite elemente kognitivnog procesiranja, mehanizmi koji se nalaze u osnovi metakognitivnih procesa razlikuju se u

različitim fazama procesiranja zadatka (Efklides, 2002, 2006a; Efklides, Kourkoulou, Mitsiou i Ziliaskopoulou, 2006). Na primjer, na početku rada na zadatku nedostatak interesa može biti povezan s odlukom o malom ulaganju truda u rad na zadatku, a u kasnijoj fazi može biti ključan u odluci o završavanju rada na zadatku, dok drugi elementi metakognitivnog doživljaja npr. osjećaj težine može biti ključan za promjenu strategije ili regulaciju ulaganja truda. Metakognitivni doživljaj je stoga potrebno pratiti u različitim fazama rada na zadatku – tijekom rada, ali i prospektivno (neposredno prije rada, u fazi pripreme za rješavanje zadatka) i retrospektivno (neposredno nakon rada, u fazi reakcije i refleksije).

Treći elementi metakognitivnog doživljaja, *specifična znanja vezana uz zadatak*, produkt su analitičkih i svjesnih procesa analize osobina i zahtjeva zadatka, pa su prisutna u samoiskazima učenika koji se prikupljaju tijekom rada na zadatku (Efklides, 2001). Flavell (1979) ta specifična znanja vezana uz zadatak naziva *online* metakognitivno znanje, međutim, razlikuju se od metakognitivnih znanja upravo u svojoj specifičnosti i trenutnosti. Ta specifična znanja predstavljaju svjesnost karakteristika zadatka i metakognitivnog znanja vezanog uz zadatak i strategije, a razlikuje se od ostalih elemenata metakognitivnog doživljaja upravo u tome što su usmjerena na praćenje karakteristika zahtjeva zadatka i na procedure vezane uz procesiranje zadatka, a ne na afektivni odgovor na osobine kognitivnog procesiranja. Stoga se ponekad svrstavaju u metakognitivne vještine (Efklides, 2006b). Od ostalih elemenata metakognitivnog doživljaja razlikuju se i po tome što su više povezana s učinkom rješavanja problema ili učenja (Efklides, 2001). Povezanost metakognitivnih osjećaja i učinka je relativno niska, uslijed toga što se metakognitivni osjećaji temelje na inferencijalnim procesima koji nužno ne odražavaju stvarne ishode procesiranja (Efklides, 2001). Iako je točnost metakognitivnog doživljaja često niska, poboljšava se s vježbom (Efklides, 2006b).

### *Metakognitivne vještine*

Metakognitivne vještine ili strategije se aktiviraju na temelju informacija koje nastaju kao produkt metakognitivnog doživljaja ili vanjske povratne informacije (Efklides, 2006b). To su aktivnosti praćenja i kontrole kognitivnih procesa koje predstavljaju proceduralno znanje potrebno za stvarnu regulaciju i kontrolu procesa učenja. Iako se uglavnom podrazumijeva da se metakognitivne vještine odvijaju svjesno i namjerno, one se mogu automatizirati i okupirati manje kapaciteta pažnje nakon dugotrajne vježbe (Efklides,

2009). Kao takve, metakognitivne vještine se mogu aktivirati kad se identificira problem u kognitivnom funkcioniranju koji zahtijeva kontrolu, odnosno kad metakognitivni doživljaj prepozna nefluentnost kognitivnog procesiranja (Efklides, 2009).

U različitim zadacima manifestiraju se različite metakognitivne vještine, ali imaju zajednički temelj u obavljanju aktivnosti kontrole i regulacije kognicija (Veenman i sur., 2006).

U pripremnoj fazi učenja metakognitivne vještine uključuju orijentaciju, reprezentaciju zahtjeva zadatka i praćenje razumijevanja tih zahtjeva, aktiviranje znanja, planiranje koraka izvršavanja zadatka, odabir prikladnih strategija rješavanja zadatka, postavljanje međuciljeva i alokaciju resursa potrebnih za rad na zadatku. Za vrijeme trajanja rada na zadatku to su praćenje izvedbe planiranih aktivnosti i reguliranje kognitivnih aktivnosti, započinjanje, završavanje ili mijenjanje kognitivnih strategija, detektiranje pogrešaka, mijenjanje plana, organizacija vremena i resursa za rješavanje zadatka. Na kraju rada na zadatku, metakognitivne vještine se odnose na vrednovanje ishoda procesiranja zadatka i refleksiju rada – procjenu produkata učenja, učinkovitosti i kvalitete vlastitog učenja.

Istraživanja pokazuju da su različite metakognitivne vještine međusobno visoko povezane – detaljna orijentacija na zadatku vodi točnom reprezentiranju zadatka i kvalitetnom planiranju, što vodi sustavnijem radu i boljem praćenju, kontroli i regulaciji aktivnosti tijekom rada na zadatku, što onda pogoduje i kvalitetnijem vrednovanju ishoda procesiranja i refleksiji vlastitog učenja (Veenman i sur., 2004). Stoga se pokazuje da mali broj mjera u istraživanju može reprezentirati širi skup metakognitivnih vještina.

Istraživanja, nadalje, pokazuju da važnost metakognitivnih vještina ovisi o prirodi zadatka (Veenman, 2007). Naime, pokazuje se da metakognitivne vještine imaju značajnu ulogu u složenim, teškim i novim zadacima, o kojima učenici nemaju mnogo prethodnih znanja, dok se ne koriste mnogo kad zadaci zahtijevaju automatizirane odgovore (Sperling, Howard i Staley, 2004). U zadacima istraživačkog učenja prikazanima u programu FILE, doprinos metakognitivnih vještina objašnjenju učinka u učenju djelomično je nezavisan od inteligencije, što znači da djeluje kombinirani model, prema kojemu intelektualne sposobnosti i metakognitivne vještine dijele dio varijance učinka, ali metakognitivne vještine imaju i nezavisan doprinos objašnjenju učenja (Veenman i sur., 2004). Prins, Veenman i Elshout (2006) na ponešto složenijem zadatku istraživačkog učenja (Optics Lab) dobivaju isti nalaz i zaključuju da na zadacima srednje kompleksnosti vrijedi

kombinirani model odnosa metakognitivnih vještina i inteligencije. Na složenim i teškim zadacima, kad rješavanje zadataka zahtijeva improvizaciju i uporabu heuristika, učenici se izrazito oslanjaju na metakognitivne vještine, pa su one važna determinanta uspješnog učenja. Metakognitivne vještine tad doprinose objašnjenju rezultata učenja čak i više nego inteligencija (Veenman, Prins i Elshout, 2002; Veenman i Spaans, 2005). Kako učenici uvježbavaju zadatke, utjecaj metakognitivnih vještina slabi, a intelektualnih sposobnosti se povećava (Prins i sur., 2006).

### ***2.6.2. Motivacija i samoregulirajuće učenje***

Da bi učenici bili samoregulirani, nije dovoljno imati bogat repertoar kognitivnih vještina, prikladno metakognitivno znanje o zahtjevima zadatka i kognitivnim strategijama njegovog rješavanja, kao i vještine odabira, praćenja i regulacije korištenja tih strategija u pojedinim situacijama učenja. Samoregulirajuće učenje je izrazito ovisno o spremnosti učenika da postave vlastite ciljeve učenja, djeluju samoinicijativno i orijentirano prema ovladavanju materijala kojeg uče i posjeduju sklop adaptivnih motivacijskih vjerovanja i stavova koji određuju njihovu spremnost na učenje, spremnost na ulaganje napora i održavanja truda u situacijama pojavljivanja prepreka, gubitka interesa itd. Tijekom učenja, učenici moraju samoregulirati i vlastitu motivaciju za učenje, ulaganje truda i emocije (Wolters, 2003; Boekaerts i Cascallar, 2006; Sansone i Thoman, 2005).

Pregledom postojećih definicija samoregulirajućeg učenja može se ustvrditi da je u srži samoregulirajućeg učenja upravo očekivanje da se kognitivni procesi ne događaju u izolaciji, već su usmjereni cilju i pod utjecajem motivacijskih, emocionalnih i kontekstualnih čimbenika (Pintrich, 2003).

Dosadašnja empirijska istraživanja koja su se bavila utjecajima motivacije na učinke učenja, međutim, nisu bila veoma uspješna u otkrivanju tih utjecaja (Rheinberg, Vollmeyer i Burns, 2000), uglavnom zbog toga što su ispitivala udaljene utjecaje – stabilne motivacijske sklopove koji nisu osjetljivi na pojedine situacijske uvjete, a koristila su i neprikladne upitničke mjere općih motivacijskih konstrukata. Stoga i ne čudi što se u istraživanjima koja motivaciju ispituju kao osobine ličnosti dobivaju niske povezanosti između motivacijskih varijabli i učenja (Rheinberg i sur., 2005). Čak i kad je u istraživanjima utvrđena povezanost motivacije i učenja, premalo je pažnje usmjereno na procese kojima motivacija utječe na procese i ishode učenja (Rheinberg i sur., 2005), kao i na kontekstualiziranost (Järvelä, 2001) i dinamičnost tih procesa (Järvelä, Salonen i

Lepola, 2002). Rheinberg i sur. (2000) zaključuju da se začuđujuće malo zna o tome kako su posredovani utjecaji motivacije na učenje, posebice imajući na umu da je samoregulirajuće učenje bilo predmet brojnih teorijskih i empirijskih razmatranja. Iako su dosadašnja istraživanja motivaciju uglavnom tretirala kao prediktor učenja i ispitivala kako motivacija usmjerava, pospješuje ili ograničava samoregulirajuće učenje, vrlo je malo istraživanja o ulozi motivacijskih čimbenika u aktivaciji i stjecanju znanja, procesima pažnje, rezoniranja i mišljenja (Pintrich, 2003), kao i istraživanja o tome kako učenici prate, kontroliraju i reguliraju svoju motivaciju (Pintrich, 1999). Nedostaju i istraživanja o tome kako korištenje različitih kognitivnih i metakognitivnih strategija utječe na motivaciju učenika i njihovu procjenu vlastite samoefikasnosti, interesa, ciljeva koje postavljaju itd., odnosno istraživanja koja istražuju recipročne i interaktivne veze između motivacije i samoregulacije (Wolters, 2003).

Usmjeravajući se upravo na ispitivanja motivacijskih čimbenika koji usmjeravaju i održavaju aktivnosti učenika tijekom epizoda učenja, Vollmeyer i Rheinberg postavljaju kognitivno-motivacijski procesni model utjecaja motivacije na samoregulirajuće učenje (Rheinberg i sur., 2000). Model prikazuje lanac koji započinje s osobinama učenika i osobinama situacije učenja kao determinantama situacije učenja za pojedinog učenika u određenom trenutku. Stabilne motivacijske osobine učenika su npr. njegovi interesi, motivacijska orijentacija, opća vjerovanja o samoefikasnosti i sl., a osobine situacije npr. područje učenja, struktura zadatka, težina zadatka, karakteristike socijalnog okruženja u kojem se učenje odvija, potencijalni dobici i gubici koji proizlaze iz rada na zadatku itd. Navedene osobine učenika i situacije zajedno, u interakciji, određuju početnu motivaciju učenika za rad na zadatku, odnosno utječu na to koje ciljeve učenik postavlja na zadatku, kakva ima očekivanja o vlastitom uspjehu, kakve poticaje percipira mogućima u situaciji učenja. Te situacijski specifične varijable uvjetuju kvalitetu (vrstu) i snagu početne motivacije učenika na zadatku, koja, pak, određuje posredujuće procese koji djeluju tijekom učenja i utječu na njega. Ti procesi koji posreduju između početne motivacije za učenje i učenja mogu biti različiti, ovisno o vrsti zadatka. Kod samoregulirajućeg učenja u kojem učenik slobodno odlučuje o izboru strategija učenja, pretpostavlja se da su posredujuće varijable vrijeme provedeno na zadatku ili učestalost aktivnosti učenja, vrsta/kvaliteta aktivnosti učenja, funkcionalno stanje (fiziološka i psihološka aktivacija, koncentracija, *flow*) i motivacijsko stanje učenika (snaga i kvaliteta motivacije tijekom učenja). Te posredujuće varijable utječu na učinke učenja, koji proizlaze iz specifičnih

aktivnosti učenja koje učenik provodi na određenom zadatku u pojedinoj epizodi učenja. Učinak učenja ujedno predstavlja i kraj lanca u modelu koji postavljaju Vollmeyer i Rheinberg.

U svojim empirijskim provjerama modela autori su se usmjerili na analizu odnosa funkcionalno bliskih varijabli u modelu, pa su u više istraživanja istraživali odnose početne motivacije, posredujućih procesa i učinka na jednom zadatku istraživačkog učenja. Na tome zadatku koji opisuju Rheinberg i suradnici (2000) učenici trebaju shvatiti i naučiti kontrolirati računalno prezentirani složeni model odnosa između nekih varijabli. Rad na zadatku uobičajeno je za učenike trajao između jedan i četiri sata, i kao takav je omogućavao ponavljano mjerenje posredujućih varijabli tijekom učenja (Rheinberg i sur., 2005).

Početna motivacija je u ovim istraživanjima konceptualizirana kroz četiri situacijski specifična motivacijska faktora (vjerojatnost uspjeha/ uvjerenje u sposobnost ovladavanja zadatkom, percepcija zadatka kao izazova, strah od neuspjeha/ anksioznost i interes) koji su mjereni prije početka rada na zadatku (Rheinberg i sur., 2000). U različitim istraživanjima korištene posredujuće varijable bile su vrijeme rada na zadatku, odnosno perzistencija na zadatku, kvaliteta aktivnosti učenja (sustavnost strateškog djelovanja/ korištenje strategije kontrole varijabli) i motivacijsko stanje tijekom učenja. Te su mjere uzimane nakon svake od tri serija pokusa unutar faze učenja (nakon svakih šest pokusa). U istraživanjima (npr. Vollmeyer, Rollett i Rheinberg 1997; Vollmeyer i Rheinberg, 2000; 2006) je utvrđeno da strateška sustavnost posreduje u odnosu početne motivacije i rezultata učenja – s povećanjem početne motivacije, rasla je i sustavnost pri radu, što je imalo pozitivan učinak na stjecanje znanja. U nizu istraživanja istih autora (Vollmeyer i sur., 1997; Vollmeyer i Rheinberg, 1998; prema Rheinberg i sur., 2000; Vollmeyer i Rheinberg, 2000, 2006) utvrđen je i značajan posredujući utjecaj motivacijskog stanja tijekom rada na zadatku. Viša početna motivacija vodila je sustavnijem pristupu rješavanja zadatka i pozitivnijem motivacijskom stanju tijekom rada na zadatku, a te su posredujuće varijable bile povezane s boljim rezultatima učenja. Posredujuće varijable su također bile međusobno povezane – pozitivno motivacijsko stanje tijekom učenja povećavalo je vjerojatnost da će učenici koristiti sustavan pristup, usprkos kognitivnom naporu i potrebi dubljeg procesiranja koji takav pristup zahtijeva (Vollmeyer i sur., 1997; Vollmeyer i Rheinberg, 2000).

Posredujući učinak vremena provedenog na zadatku nije uvijek bilo jednostavno pokazati (Rheinberg i sur., 2005). U istraživanjima Vollmeyer i suradnika (1997) i Vollmeyer i Rheinberga (2000) početna motivacija je pozitivno utjecala na broj provedenih serija eksperimenata, ali perzistencija nije bila pozitivno povezana s učinkom, što znači da učenici koji su bili perzistentni nisu imali u prosjeku bolji učinak na zadatku. Učenici koji su brže svladali model zadatka, odnosno koji su stekli više znanja o modelu, koristili su manje serija eksperimenata. Radi se o tome da su učenici koji imaju visoke kognitivne sposobnosti brzo postizali visoku razinu postignuća na zadatku i završavali svoje učenje, dok su učenici nižih sposobnosti, ali visoke motivacije koristili više vremena za dostizanje iste razine kompetencije. Pomoću većeg broja provedenih serija eksperimenata ti učenici su zapravo kompenziraju početne deficite u stečenom znanju. Stoga nije potvrđen posredujući učinak vremena provedenog na zadatku, kad se učenici uspoređuju međusobno (Rheinberg i sur., 2000). Međutim, kad se usporedba provodi intraindividualno, povećanje vremena provedenog na zadatku povećavalo je učinak učenika na tome zadatku.

U istraživanju Vollmeyer i Rheinberga (1999) proširen je krug potencijalnih posredujućih varijabli na nove kognitivne varijable (testiranje hipoteza, analizu rezultata eksperimenata i korištenje strategija za otkrivanje ciljnog stanja modela), metakognitivne procese planiranja i samokontrole te emocionalne reakcije. Analize su potvrdile povezanost između pojedinih kognitivnih procesa, kao i posredujući učinak novih kognitivnih varijabli između početne motivacije i učinka na zadatku, ali nisu uspjele pokazati učinak metakognicije i emocionalnih reakcija zbog izrazito malog broja iskaza tih procesa u verbalnim protokolima.

Isti autori (Rheinberg, Vollmeyer i Rollett, 2002) su utvrdili postojanje skupina učenika s različitim obrascima odnosa motivacijskih i kognitivnih varijabli. Uspoređivali su različite profile samoregulacije učenja i utvrdili da posjedovanje kognitivnih sposobnosti i početne motivacije nije dovoljno za objašnjenje stjecanja znanja o složenom modelu, pa pretpostavljaju da bi u obzir trebalo uzeti metastrateško znanje, odnosno metakognitivne strategije učenika (Rheinberg i sur., 2002). To, dakako, ne umanjuje značaj motivacije u određivanju rezultata učenja. Naime, u istraživanju Vollmeyera i suradnika (1997) u kojem je učenicima objašnjen optimalan pristup radu na zadatku, pa se moglo očekivati da su učenici međusobno izjednačeni po metastrateškom znanju (iako ne i po primjeni tog znanja, odnosno po proceduralnom znanju), povezanost između motivacije i sustavnosti



rada na zadatku je bila pozitivna, posebice u kasnijim fazama učenja, budući da primjena sustavnih strategija rada zahtijeva ulaganje mentalnog napora.

Autori napominju da su dobiveni rezultati istraživanja primjenjivi samo na usporedive situacije učenja (Rheinberg i sur. 2005), odnosno situacije u kojima učenici individualno stječu znanje o modelu varijabli na računalno prikazanom zadatku (Vollmeyer i Rheinberg, 2000). Mijenjanje vrste zadatka ili nekih situacijskih osobina (npr. povećanje važnosti ishoda učenja) može promijeniti način na koji motivacijski čimbenici utječu na proces i rezultate učenja. Zanimljivo je, primjerice, da već najava pružanja povratne informacije o tome koliko veza među varijablama su učenici ispravno identificirali utječe na proces i rezultate učenja - smanjuje se broj serija eksperimenata koje učenici provode, povećava sustavnost rada na zadatku i stjecanje znanja o modelu zadatka (Vollmeyer i Rheinberg, 2005). Autori zaključuju da su potrebna istraživanja u kojima se sustavno variraju osobine zadatka i situacija učenja, kako bi se ispitao utjecaj tih promjena na odnose motivacije i učenja (Rheinberg i sur, 2005). Slijedom toga, Vollmeyer i Rheinberg (2006) su provjerili primjenjivost svog kognitivno-motivacijskog procesnog modela u situaciji učenja u hipermedijskom okruženju, kao i na primjeru pohađanja i polaganja ispita iz jednog sveučilišnog kolegija, te utvrdili ponešto drugačije obrasce posredujućih utjecaja između početne motivacije i učinka učenika. Ipak, u različitim situacijama učenja se potvrđuju osnovna načela koja postulira model - učenici ulaze u situaciju učenja s određenim motivacijskim sklopom koji utječe na to kako učenici pristupaju učenju, a određeni, za situaciju specifični elementi posreduju između utjecaja početne motivacije i učinka koji učenici ostvaruju u pojedinoj situaciji učenja.

## **2.7. Mjerenje samoregulirajućeg učenja**

Prva istraživanja samoregulirajućeg učenja oslanjala su se na konstrukte poput osobina ličnosti ili sposobnosti, te su samoregulaciju učenja promatrala kao relativno stabilnu sklonost reagiranja u različitim situacijama učenja, neovisno o kontekstu u kojem se učenje odvijalo (Boekaerts i Cascallar, 2006). U svrhu procjene samoregulirajućeg učenja korištene su uglavnom upitničke mjere, a ponekad i strukturirani intervjui i nastavničke procjene učeničkih samoregulacijskih kapaciteta. Upitnici samoregulirajućeg učenja uobičajeno su od učenika tražili da generaliziraju svoja ponašanja kroz različite situacije učenja, a strukturirani intervjui da se dosjete tipičnih ponašanja u različitim situacijama (Winne i Perry, 2005). Iako takve mjere mogu zahvatiti opću sklonost reagiranja u

različitim situacijama učenja, kao i impresije učenika o tome kako uče, pod utjecajem su pristranosti kao sve retrospektivne mjere (Nolen, 2006).

Kasnije se u istraživanjima odustalo od generaliziranih mjera samoregulirajućeg učenja, pa se samoregulirajuće učenje počelo ispitivati sužavanjem konteksta učenja na pojedina područja učenja (npr. područje matematike, čitanja), budući da su istraživanja jasno ukazivala na razlike u samoregulaciji ovisno o tome o kojem području učenja je riječ (Winne i sur., 2002; Boekaerts i Cascallar, 2006). I u ovoj fazi razvoja istraživanja samoregulirajućeg učenja dominantno su se koristile upitničke mjere o motivacijskim i (meta)kognitivnim elementima učenja, ali sada unutar pojedinim područja učenja.

Oslanjajući se na nekontekstualizirane konstrukte i njihove upitničke mjere, prva istraživanja samoregulirajućeg učenja nisu mogla točno opisati procese koji se odvijaju tijekom samoregulacije, niti objasniti veze između općih motivacijskih i metakognitivnih mjera i učinaka koji učenici ostvaruju u učenju (Niemi-virta, 2006). Kako bi se ispitalo što učenici misle i osjećaju tijekom procesa učenja, i kako bi se utvrdila uloga tih misli i osjećaja u procesu reguliranja i kontrole učenja, ključno je zahvatiti te procese onako i onda kad se oni događaju.

Noviji pristupi izučavanja samoregulirajućeg učenja stoga se temelje na mjerenju samoregulacijskog učenja kao procesa, događaja (Winne i Perry, 2005), te se usmjeravaju na ispitivanje situacija učenja u trenu kad ih učenici doživljavaju (Boekaerts i Cascallar, 2006; Ainley i Patrick, 2006).

Podrazumijeva se da je samoregulirajuće učenje kontekstualizirani, kompleksni i dinamični proces, čije mjerenje treba biti usklađeno s prirodom procesa (Butler i Cartier, 2005). Kontekstualiziranost se odnosi na ovisnost procesa i ishoda učenja o konkretnoj situaciji učenja, odnosno na prihvaćanje toga da situacijski i drugi okolinski čimbenici oblikuju doživljaje i aktivnosti učenika. Kompleksnost se očituje u dinamičkim i cikličkim kognitivnim, motivacijskim i regulatornim procesima koji su pod utjecajem brojnih čimbenika – učenikovih interesa, znanja, procjena situacije učenja, emocija itd., a koji ne moraju uvijek biti dostupni svijesti učenika. Dinamičnost se ogleda u tome što se samoregulirajuće učenje odvija kao događaj u vremenu, u ciklusima aktivnosti. Usklađujući mjerenje samoregulirajućeg učenja s njegovom kontekstualiziranom, kompleksnom i dinamičnom prirodom, jasno je da mjerenje mora zahvatiti kako se sastavnice samoregulirajućeg učenja mijenjaju unutar i kroz epizode učenja (Butler i

Cartier, 2005). Istraživanja se često usmjeravaju na mikro razinu procesa koji se odvijaju dok učenici provode pojedine aktivnosti učenja (npr. Ainley i Patrick, 2006). Tada se istraživanja izvode kao tzv. mikrorazvojna (Granott i Parziale, 2002) ili mikrogenetska istraživanja (Siegler i Crowley, 1991; Kuhn, 1995), u kojima se učenici opetovano u relativno kratkim vremenskim intervalima izlažu situaciji učenja (radu na jednom zadatku) kako bi se istraživali procesi promjena u znanju, vještinama i razumijevanju. Na temelju zgusnutih i intenzivnih ponavljanih mjerenja učenika u razvojnim razdobljima u kojima se očekuje relativno brzo mijenjanje ispitivanih osobina, procesi promjena se neposredno zahvaćaju, onako kako se događaju (Granott i Parziale, 2002). Detaljnost i blizina podataka o procesima promjena koji se prikupljaju ovim istraživanjima omogućuje praćenje toga kako učenici konstruiraju nova znanja i razvijaju strategije rada na zadatku. Pritom se analiziraju obrasci, obilježja i mehanizmi promjena koji se manifestiraju u procesu i pokušavaju se utvrditi izvori, stopa, putovi, širina i varijabilitet opaženih promjena (Siegler, 2006; Flynn i Siegler, 2007).

Tretirajući samoregulirajuće učenje kao proces, istraživanja nastoje zahvatiti iskustva učenika u ponavljanim situacijama učenja, identificirati samoregulacijske procese onako kako se oni odvijaju, u slijedu u kojem se događaju, te analizirati raspored, poredak, obrasce i odnose među pojedinim sastavnicama procesa u pojedinim fazama učenja (Ainley i Patrick, 2006). Prate se i bilježe sekvence interakcija učenik – zadatak, a pritom se uobičajeno koriste mjere samo s jednom česticom (engl. *single item self-reports*). Raspravljajući o pouzdanosti i valjanosti takvih mjera, Ainley i Hidi (2002) i Ainley i Patrick (2006) objašnjavaju da klasične mjere pouzdanosti (test-retest i unutarnja konzistencija) i valjanosti nisu prikladne za mjerenje promjenjivih stanja i stanja koja su pod utjecajem usmjeravanja pažnje, kakva se zahvaćaju u mjerenjima samoregulirajućih procesa. Zaključuju da se, u slučaju konstrukata koji su dovoljno usko definirani, koji su jednodimenzionalni i jednoznačni za ispitanike, mjere s jednom česticom (Likertovog tipa) mogu smatrati dobrim pokazateljima mjerenog stanja. Valjanost takvih mjera, najbolje je utvrditi demonstriranjem konvergentnih i diskriminativnih odnosa s drugih varijablama koji su u skladu s teorijskim očekivanjima (Ainley, 2006; Ainley i Patrick, 2006; Efklides, 2006a). Utvrđivanjem konvergentne i diskriminativne valjanosti korištenih mjera jača uvjerenje u njihovu konstruktivnu valjanost, ali i praktičnu primjenjivost za predikciju rezultata učenja (Veenman, 2008).

Turner (2006) umjesto isprekidanog mjerenja samoregulacije u sukcesivnih vremenskim točkama, predlaže kontinuirano mjerenje aktivnosti i uzimanje cjelokupne aktivnosti kao jedinice analize. Fokusiranje na kompletnu aktivnost kroz vrijeme otkriva punoću i dinamičnost samoregulacijskih procesa te omogućava objašnjavanje toga kako se pojedini elementi samoregulacijskih procesa mijenjaju ili razvijaju. Osnova samoregulacije je upravo u promjeni, i mjerenje mora zahvatiti tu promjenu.

Mjerenje samoregulirajućeg učenja kao procesa zahtijeva korištenje kompleksnijih mjernih postupaka koji omogućuju valjanije zahvaćanje informacija o stanjima i različitim procesima kroz koje učenik prolazi kad samoregulirano uči (Winne i Perry, 2005). U želji da mjerenje samoregulirajućeg učenja reflektira kompleksnost i varijabilitet unutar procesa učenja, prepoznaje se da niti jedna pojedinačna metoda mjerenja nije dovoljna za zahvaćanje svih samoregulacijskih procesa, opis varijacija u korištenju strategija u vremenu i utvrđivanje promjenjivih obrazaca misli, osjećaja i aktivnosti tijekom procesa učenja, te se za mjerenje različitih aspekata samoregulacije preporuča ponavljano korištenje kombinacije različitih instrumenata, koji ne dijele isti izvor pogreške (Boekaerts i Cascallar, 2006). Osim korištenja različitih mjera za iste konstrukte, potrebno je mjeriti različite manifestacije iste pojave i prikupljati podatke iz različitih izvora, kako bi se provela triangulacija podataka (Winne i Perry, 2005).

Kako bi se mjerenjima zahvatili procesi promjena, mjerni instrumenti moraju biti «nenametljivi» te se uklopiti u autentične zadatke. Mjerenja trebaju biti ponavljana u različitim fazama procesa učenja ili rješavanja zadatka (prije početka rada, tijekom rada, nakon rada), kako bi se prikupile informacije o tome kako se neki specifični procesi održavaju ili mijenjaju tijekom učenja (Efklides, 2006a). Primjena mjera mora biti brza, mora se odvijati bez produžavanja trajanja zadatka i bez ometanja procesa učenja, pažnje i koncentracije (Ainley i Patrick, 2006). Ainley (2006) argumentira primjerenost korištenih *online* mjera o afektivnim stanjima tijekom rada na zadatku nalazom da učenicima treba samo 30-tak sekundi za odgovaranje na pitanja.

U istraživanjima se također često kombinira kvalitativna i kvantitativna istraživačka metodologija (Patrick i Middleton, 2002), odnosno istraživanja se temelje na pragmatičnom pristupu miješanog modela (Turner, 2001). Takva istraživanja omogućuju zahvaćanje kompleksnosti pojave i pružaju bogatu, holističku, kontekstualiziranu deskripciju procesa učenja, koja može odgovoriti na pitanja što, kako, zašto i kada iz perspektive učenika, kao i omogućiti metodološku triangulaciju (Patrick i Middleton,

2002). Kombiniranjem različitih vrsta podataka, opažanjem cjelokupnih epizoda učenja i zahvaćanjem finih promjena u ponašanjima i doživljajima upravo u vrijeme kad se one događaju, takva istraživanja objedinjuju prednosti koje nude «čista» kvalitativna i kvantitativna istraživanja procesa učenja. Kvalitativni pristupi proučavanju samoregulirajućeg učenja omogućuju finu i detaljnu analizu slučajeva samoregulacije, naglašavaju utjecaj konteksta u kojem se proces učenja događa i usmjeravaju se na razumijevanje kompleksnosti međusobne zavisnosti tih različitih utjecaja na učenje i dokumentiranje veza između situacija učenja i ishoda vezanih uz samoregulaciju učenja (Butler, 2002).

Sve navedeno sugerira da istraživači u području istraživanja samoregulacije učenja imaju mnogo slobode u izboru postupaka za mjerenje pojedinih elemenata samoregulirajućih procesa. Nepostojanje standardiziranih postupaka mjerenja zapravo odražava potrebu i svjesno nastojanje istraživača da prilagode korištene mjere specifičnim situacijama učenja korištenim u pojedinim istraživanjima, kao i razvojnim razinama učenika koji sudjeluju u situacijama učenja (Winne i Perry, 2005).

Imajući na umu da različite sastavnice samoregulirajućeg učenja nisu dostupne opažanju (već se o njima zaključuje na temelju indirektnih mjera), u istraživanjima se koriste različiti postupci i metode – upitnici, intervjui, protokoli 'misli naglas', opažanja, praćenje tragova događaja i procesa, dnevnici učenja, računalni automatski zapisnici učeničkih aktivnosti. Zahvaćaju se ponašanja koja se mogu opažati, ali i unutarnji procesi, kao i informacije iz konteksta u kojem se učenje odvija.

Mjerne je postupke potrebno odabrati ovisno o tome koja sastavnica samoregulirajućeg učenja se mjeri. Metakognitivne vještine je, primjerice, neprikladno ispitivati upitničkim mjerama, jer učenici nemaju dobar uvid u vlastite metakognitivne procese (Prins i sur., 2006), koji se, osim toga, mogu odvijati automatski, bez svjesnosti učenika o njihovom postojanju. Neke procese je učenicima teško verbalno artikulirati, iako ih koriste tijekom učenja, dok su neki drugi procesi dostupni samoiskazima, ali se ne prenose u ponašanje (MacLeod, Butler i Syer, 1996). Nadalje, odgovaranje na opća pitanja o (meta)kognitivnim aktivnostima ne odgovara specifičnostima zahtjeva pojedinih zadataka i specifičnosti ciljeva koje učenici postavljaju u njima. Stoga ne čudi da je povezanost upitničkih metakognitivnih mjera sa stvarnim ponašanjem gotovo nulta (Prins, 2002; Veenman i sur., 2006).

Slični problemi dostupnosti, istinitosti i cjelovitosti javljaju se i kod verbalnih samoiskaza koje učenici daju za vrijeme ili nakon rada na zadatku. Međutim, osim navedenih problema, događa se da u slučaju teških zadataka učenici prestanu govoriti, pa je učenike potrebno neprestano poticati (Ericsson i Simon, 1993). Nadalje, kod korištenja samoiskaza za ispitivanje kognitivnih i metakognitivnih procesa, posebice kod djece koja imaju ograničene jezične kompetencije (Wilson, 2000), postoji i problem moguće reaktivnosti samog postupka. Naime, potreba davanja verbalnog iskaza tijekom rada na zadatku o tome što učenik misli i što radi na zadatku može utjecati na same (meta)kognitivne procese, odnosno mijenjati ih. Učinci na učenje mogu biti pozitivni, budući da eksplicitno objašnjavanje pristupa rada (formuliranje pravila, strategija) pomaže stjecanju znanja, ali može doći i do usporavanja rada na zadatku (Vollmeyer i Rheinberg, 1999). Istraživanja u području istraživačkog učenja, međutim pokazuju da davanje verbalnih iskaza tijekom rada na zadatku ne interferira s kognitivnim i metakognitivnim procesima (Wilhelm i Beishuizen, 2004), ali ih može usporiti (Veenman i Spaans, 2005). Neka druga istraživanja, pak, pokazuju da do interferencije dolazi ukoliko se od učenika traži da objašnjavaju, a ne samo opisuju vlastito kognitivno procesiranje (Winters i sur., 2008). Siegler (2006) također utvrđuje da neposredni retroaktivni verbalni samoiskazi nisu reaktivni ukoliko se daju u trenu kad su tragovi procesiranja još aktivni u radnom pamćenju, ukoliko su ispitivani procesi dovoljno dugi da imaju reprezentaciju u radnom pamćenju i ukoliko su relativno jednostavni za opisivanje. Siegler (2006) zaključuje da korištenje samoiskaza doprinosi valjanosti mjerenja uporabe strategija, ukoliko se kombinira s opažanjem. Ipak, kako bi se smanjila mogućnost reaktivnosti mjerenja, važno je izbjeći davanje uputa ili informacija učenicima koje ih navode na korištenje određene strategije, jer takve upute imaju značajan utjecaj na ponašanje ispitanika (Siegler, 2006).

Osim moguće reaktivnosti samog postupka, problem verbalnih iskaza kao metode mjerenja procesa učenja je u tome što mogu biti pod utjecajem potrebe učenika za pozitivnom samoprezentacijom i njegovim doživljajem zahtjeva istraživanja.

Ipak, učenički samoiskazi, odnosno upitničke mjere dobro reprezentiraju perspektivu učenika u situacijama kad oni rade na zadatku (Ainley, 2006), pa su korisni za bilježenje učeničkih iskustava i interpretacija situacije učenja (Boekaerts, 2002), mjerenje njihovog prospektivnog metakognitivnog doživljaja, kao i za utvrđivanje retrospektivnog pogleda učenika na obavljeni zadatak (Ainley, 2006). Samoiskazi učenika omogućuju prikupljanje opisa i objašnjenja kognitivnih, metakognitivnih i motivacijskih procesa koje istraživač ne

može opažati, pa pružaju dragocjene informacije o učeničkim percepcijama toga kako reguliraju svoje učenje (Perry i Winne, 2006). Razlikuju se, dakako, *offline* mjere uzete prije ili poslije rada na zadatku i *online* mjere korištene za vrijeme procesiranja zadatka. Online mjere su prediktivnije za učinak učenja nego offline mjere (Veenman i sur, 2006), a osim toga, zbog ponavljanih mjerenja tijekom rada na zadatku omogućuju zahvaćanje različitih komponenti procesa u slijedu u kojem se događaju (Nolen, 2006; Ainley, 2006).

Turner (2006) navodi da su se istraživanja samoregulirajućeg učenja prečesto koncentrirala samo na samoiskaze ispitanika o vlastitim procjenama i doživljajima, bez uključivanja mjera ponašanja. Autorica apelira na promjenu istraživačkog fokusa s onoga što učenici misli na to što rade kad se istražuju procesi samoregulacije, te upućuje na potrebu uvođenja mjera ponašanja uz mjere ciljeva, stavova, vjerovanja itd. U tome smislu, u mjerenje samoregulirajućeg učenja potrebno je uvesti praćenje tragova o samoregulirajućem učenju koje učenici ostavljaju kad rade na zadatku, kao i koristiti opažanja rada. Praćenje tragova procesa učenja omogućuje praćenje automatiziranih kognitivnih aktivnosti koji se ne otkrivaju glasnim razmišljanjem ili samoiskazom, a osigurava točnu i vremenski određenu deskripciju interakcija učenika i zadatka (Perry i Winne, 2006). Praćenje tragova posebice je pogodno zbog nepostojanja interferencije s procesom učenja, a jednostavno se implementira uslijed mogućnosti koje pruža suvremena računalna tehnologija. Bilježe se podaci o frekvenciji i poretku aktivnosti koje učenik poduzima, informacije o vremenu koje učenik provodi na pojedinim dijelovima zadatka, a moguće je organizirati i prostor za bilješke ili odgovore ispitanika.

Opažanje rada učenika u situaciji učenja, pak, reflektira ono što učenici rade (nasuprot onome što misle ili čega se mogu dosjetiti da su radili) i omogućuje povezivanje ponašanja s uvjetima koji su postavljeni u zadatku i dokumentiranje toga kako se rad na zadatku razvija u vremenu, a smanjuje probleme pristranosti i nedostatnih jezičnih vještina (Winne i Perry, 2005).

U istraživanjima samoregulirajućeg učenja sve se češće koristi računalna tehnologija. Različiti su sustavi u uporabi - multimedija, hipermedija, inteligentni instrukcijski sustavi, kolaborativni sustavi, simulacijski računalni programi npr. *Between the Lines* (Ainley, Hidi i Berndorff, 2002) i *gStudy* (Perry i Winne, 2006). Računalna tehnologija omogućuje prezentaciju različitih vrsta sadržaja i zadataka, a računalno okruženje pruža učeniku mnoštvo interakcija koje potiču konstrukciju znanja, metakogniciju i samoregulirajuće učenje (Lajoie, 2008; Winters i sur., 2008). Računala pomažu učenicima u obavljanju

kognitivnih zadataka potporom kognitivnih procesa, smanjuju kognitivno opterećenje preuzimanjem kognitivnih procesa niže razine i omogućuju učenicima sudjelovanje u aktivnostima koje bi inače bile izvan njihovog dosega (Osborne i Hennessy, 2006; Azevedo, 2007). U kontekstu istraživačkog učenja, računalni programi osiguravaju direktni pristup znanju iz područja, pružaju potporu u procesu formuliranja hipoteza, dizajnu eksperimenata, predviđanjima i stvaranju teorija, omogućuju kolaboraciju, a pomažu i u regulaciji procesa učenja – pri planiranju, praćenju, strukturiranju i vrednovanju procesa učenja (De Jong i Van Joolingen, 1998; Van Joolingen, De Jong i Dimitrakopoulou, 2007). Uz to što računalni programi služe kao izvor podataka i sredstvo istraživanja, služe i kao sredstvo komunikacije (Murphy, 2003).

Ujedno, računalni programi predstavljaju koristan istraživački alat, budući da osiguravaju dubinsko i suptilno praćenje različitih učeničkih reakcija na specifičnom zadatku u realnom vremenu (Ainley i Hidi, 2002), kroz automatsko bilježenje učeničkih aktivnosti, ali i kroz uporabu pitanja kojima se direktno prati učeničko neposredno iskustvo na zadatku (Ainley, 2006; Ainley i Patrick, 2006). Iako računalni programi predstavljaju moćno sredstvo za praćenje aktivnosti učenika u složenim situacijama učenja, njihova uporaba za mjerenje samoregulacije učenja nije lišena određenih dvojbi. Schraw (2007), Azevedo (2007) i Winters i suradnici (2008) raspravljaju o tome da računalno okruženje može biti problematično za učenike, čak i kad su integrirani potporni, konceptualni i/ili metakognitivni alati, kao i o tome koliko se učenje u takvom okruženju može smatrati samoreguliranim. Nolen (2006) propituje koliko mogućnosti koje nudi pojedini program zapravo odvođe učenike od učenja prema pukom testiranju mogućnosti programa, kao i to koliko se na temelju praćenja tragova učenika u programu doista može zaključivati o samoregulacijskim aktivnostima učenika i značenju tih aktivnosti za učenike.

## **2.8. Istraživačko učenje kao samoregulirajuće učenje: implikacije za istraživanje**

U prethodnim je poglavljima istaknuto da vodeći teorijski modeli samoregulirajućeg učenja definiraju samoregulirajuće učenje kao kontekstualizirani, kompleksni i dinamični proces. Nedostaju, međutim, eksplicitni procesni modeli koji objašnjavaju ulogu i funkciju pojedinih sastavnica samoregulirajućeg učenja i to kako te sastavnice doprinose učenju u pojedinim situacijama učenja (Azevedo, 2009). Osim toga, složenost cijelog procesa samoregulacije učenja u pojedinim situacijama učenja vjerojatno nije dostatno



reprezentirana kroz ograničeni broj sastavnica i ograničeni broj cikličkih faza koje se pojavljuju u postojećim modelima samoregulirajućeg učenja (Zeidner i sur, 2005).

Uz to, pri deskripciji procesa samoregulacije postojeći se modeli samoregulirajućeg učenja ne spuštaju na razinu pojedinih područja učenja, pojedinih vrsta zadataka ili vrsta učenja, već daju opći pregled aktivnosti i procesa koji se mogu primijeniti na različite slučajeve samoregulacije učenja, pod pretpostavkom da se opći principi samoregulacije mogu generalizirati na različite situacije učenja. Imajući, međutim, na umu da kontekst (situacija učenja) izravno utječe na učenikove ciljeve, odluke i aktivnosti pri učenju, pa stoga i na količinu, vrstu i kvalitetu prisutnih samoregulacijskih procesa, logično je pretpostaviti različitu ulogu i međuodnose tih procesa u kontekstu različitih područja ili vrsta učenja. Iako inspirativni, postojeći teorijski modeli samoregulirajućeg učenja stoga nisu direktno i potpuno primjenjivi na područje istraživačkog učenja, koje je predmet ovog rada. Stoga ovo istraživanje ne polazi niti iz jednog teorijskog modela samoregulirajućeg učenja, već preuzima teze zajedničke svim modelima o aktivnoj ulozi učenika u procesu učenja, konstruktivističkoj prirodi učenja, složenosti i cikličnosti procesa i međuodnosima motivacijskih, metakognitivnih i kognitivnih procesa.

Prepoznaje se da istraživačko učenje, kako se ispituje u okviru integrativnog pristupa izučavanju znanstvenog razmišljanja, odgovara definiciji samoregulirajućeg učenja po sljedećim elementima:

- × Zadatak zahtijeva aktivno, samoupravljanu učenje, iako je situacija učenja jasno strukturirana.
- × Zadatak je složen pa zahtijeva primjenu različitih istraživačkih vještina i strategija, ali i naglašenu uporabu metakognitivnih procesa praćenja, kontrole i regulacije učenja.
- × Učenik sam prikuplja podatke i ima slobodu odlučivanja o izboru strategija rada na zadatku.
- × Rad učenika na zadatku nije pod neposrednom kontrolom i vođenjem istraživača (istraživač ne određuje ciljeve i strategije rada na zadatku, niti daje povratnu informaciju o radu i učinku učenika).
- × Učenik sam započinje i kontrolira vlastite aktivnosti na zadatku, odlučuje o prirodi, poretku i broju eksperimenata koje će provesti, kao i o završetku procesa učenja.

- × Ponavljani rad na istom zadatku traži postojanje motivacijske spremnosti potrebne za praćenje i upravljanje vlastitim učenjem.
- × Rješavanje zadatka traje dovoljno dugo, pa do izražaja mogu doći procesi samoregulacije učenja.
- × S obzirom da je zadatak dovoljno težak, moguće je očekivati i pozitivne i negativne rezultate učenja.

## **POGLAVLJE 3. CILJ ISTRAŽIVANJA I ISTRAŽIVAČKI PROBLEMI**

---

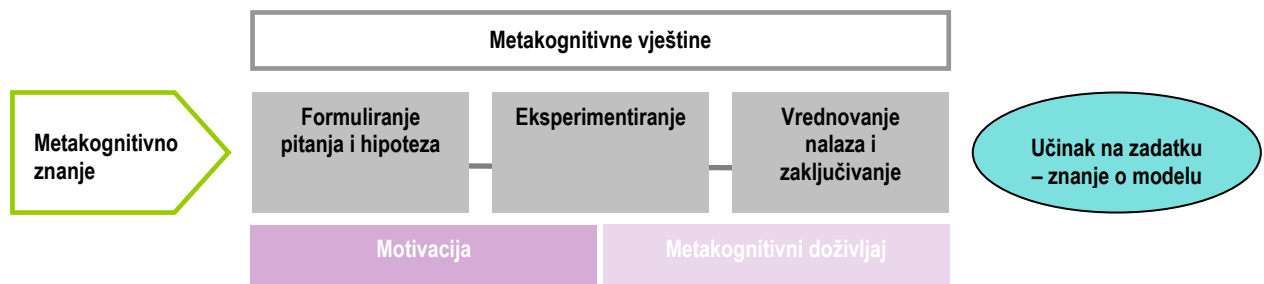
U prethodnim je poglavljima istraživačko učenje opisano kao složen oblik učenja u kojeg su, osim kognitivnih procesa, uključeni metakognitivni, motivacijski i emocionalni procesi, te je predstavljeno kao samoregulirajuće učenje – učenje koje se odvija bez neposredne kontrole istraživača i koje je, stoga, izrazito ovisno o doživljajima i aktivnostima učenika u procesu učenja.

Konceptualizirajući istraživačko učenje unutar okvira samoregulirajućeg učenja, ovo istraživanje polazi od ideje da je za razumijevanje procesa učenja i njegovih učinaka ključno razumjeti međudnose kognitivnih, metakognitivnih i motivacijskih procesa i toga kako ti procesi djeluju na učenje.

Imajući za cilj ispitivanje međudnosa pojedinih sastavnica procesa samoregulirajućeg istraživačkog učenja i njihovih doprinosa rezultatima učenja, istraživanje je usmjereno na mikrorazinu procesa koji se odvijaju dok učenici provode aktivnosti istraživačkog učenja. Tretirajući samoregulirajuće istraživačko učenje kao proces (događaj) i prateći cjelovite epizode učenja na jednom računalno prikazanom zadatku, istraživanjem se žele zahvatiti iskustva učenika i pratiti promjene u korištenju istraživačkih vještina i stjecanju znanja o predmetu ispitivanja u ponavljanim situacijama učenja. Dokumentiranjem specifičnih epizoda učenja i identificiranjem samoregulacijskih procesa onako kako se oni odvijaju u stvarnom vremenu, nastoje se utvrditi dinamički obrasci i odnosi između pojedinih sastavnica procesa učenja.

Sastavnice procesa samoregulirajućeg istraživačkog učenja uključene u istraživanje prikazane su na slici 1 kao elementi pojmovnog okvira prikazanog istraživanja. Taj je okvir nastao kombiniranjem elemenata proizašlih iz teorijskih modela i empirijskih radova predstavljenih u literaturi o sastavnicama samoregulirajućeg učenja i u literaturi o istraživačkom učenju u sklopu integrativnog pristupa istraživanjima znanstvenog razmišljanja. Predstavljeni pojmovni okvir, dakako, ne predstavlja procesni model istraživačkog učenja (budući da je rad eksplorativan u svojoj naravi), već samo prikazuje elemente samoregulirajućeg istraživačkog učenja koji su sadržani u ovome istraživačkom projektu. To su sljedeće sastavnice procesa istraživačkog učenja:

- × metakognitivno znanje o cilju zadatka i strategijama rada na zadatku
- × tri faze istraživačkog procesa koje definira korištenje određenih istraživačkih (kognitivnih) vještina ili strategija: 1) formuliranje pitanja i hipoteza, 2) eksperimentiranje i 3) vrednovanje nalaza i kauzalno zaključivanje o učinku nezavisnih varijabli na zavisnu varijablu
- × metakognitivne vještine - planiranje, praćenje i organizacija učenja na zadatku
- × motivacija za rad na zadatku i metakognitivni doživljaj rada prije, za vrijeme i nakon pojedine epizode učenja
- × stečeno znanje o kauzalnoj strukturi modela zadatka



Slika 1. Pojmovni okvir istraživanja

Temeljeći se na prikazanom pojmovnom okviru, cilj je predstavljenog istraživanja pratiti učenička iskustva kroz rad na zadatku i istražiti odnose metakognitivnih i motivacijskih sastavnica samoregulirajućeg istraživačkog učenja s istraživačkim (kognitivnim) vještinama i strategijama i učinkom na zadatku.

Iz općeg cilja istraživanja i prikazanog pojmovnog okvira formulirani su sljedeći istraživački problemi:

*1. Kako se u funkciji ponavljanih izlaganja situacijama učenja razvijaju pojedine sastavnice istraživačkog učenja?*

U okviru ovog problema ispituju se promjene od prvog do četvrtog mjerenja u:

- × znanju o kauzalnoj strukturi modela zadatka (odnosima između nezavisnih i zavisne varijable)

- × istraživačkim vještinama i strategijama koje učenici koriste pri radu na zadatku (u formuliranju pitanja i hipoteza, eksperimentiranju i kauzalnom zaključivanju)
- × korištenim metakognitivnim vještinama
- × metakognitivnom znanju o cilju i strategijama rada na zadatku
- × motivaciji i metakognitivnom doživljaju rada na zadatku

*2. Kakva je povezanost metakognitivnog znanja i metakognitivnih vještina s istraživačkim vještinama i učinkom na zadatku istraživačkog učenja?*

*3. Razlikuju li se, i na koji način, različiti motivacijski profili učenika u procesima učenja i učinku na zadatku istraživačkog učenja?*

## POGLAVLJE 4. METODOLOGIJA ISTRAŽIVANJA

---

Prijašnja su poglavlja već objasnila osnovno metodološko određenje prikazanog istraživanja i pozicionirala ga u okvire mikrorazvojnog istraživačkog pristupa i ispitivanja samoregulirajućeg istraživačkog učenja kao procesa. Zauzimanje takve istraživačke pozicije, kao što je poznato, podrazumijeva korištenje metodologije koja omogućuje praćenje promjena u radu na zadatku istraživačkog učenja zahvaćanjem cjelovitih epizoda učenja i korištenjem različitih izvora i vrsta (kvantitativnih i kvalitativnih) podataka za analizu pojedinih procesa samoregulirajućeg učenja. Cilj je ovog poglavlja detaljno predstaviti pojedine metodološke odluke, opisati postupke uzorkovanja i prikupljanja podataka, prikazati korištene mjere i instrumentarij te naznačiti postupke kvantitativne i kvalitativne analize prikupljenih podataka.

### 4.1. Ispitanici

U istraživanju su sudjelovali učenici osmih razreda osnovnih škola, koji predstavljaju dobnu skupinu od 14 do 15 godina. Ova se dobna skupina smatra pogodnom za istraživanje istraživačkog učenja u hrvatskom obrazovnom kontekstu iz dva razloga. Kao prvo, to je skupina koja se, prema Piagetovoj terminologiji, može opisati u terminima razvojne faze formalnih operacija, koja je nužna za odvijanje funkcija metakognitivne kontrole i regulacije i uspješno strateško djelovanje na zadacima istraživačkog učenja u multivarijatom kontekstu (Kuhn, 2006, 2008). Zbog tog razvojnog dostignuća, u drugom se desetljeću života može očekivati relativno brzo napredovanje istraživačkih vještina u okvirima mikrorazvojnog istraživanja, budući da ono unutar ograničenog i zgusnutog istraživačkog razdoblja pruža učenicima mogućnost stjecanja iskustava koja mogu dovesti do promjene (Kuhn, 1995).

Kao drugo, učenici završnih razreda osnovne škole predstavljaju skupinu koja je tijekom svojeg obrazovanja vjerojatno imala priliku sudjelovati u istraživačkim aktivnostima, bilo kroz grupni ili individualni rad, ili kroz opažanja nastavničkih modela na nastavi prirodoslovnih predmeta, pa je bilo opravdano očekivati da se kao skupina nalaze u procesu razvoja istraživačkih vještina, negdje između stanja potpunog nepostojanja kompetencije i stanja potpune kompetencije u ispitivanom području.

Istraživanje je provedeno u dvije zagrebačke osnovne škole, koje su izabrane prigodno<sup>7</sup>. Provođenjem istraživanja u dvije škole (umjesto u jednoj) nastojao se smanjiti eventualni utjecaj specifičnosti školske klime i školskih iskustava u prirodoslovnim predmetima, te osigurati veću mogućnost generalizacije prikupljenih podataka. Rezultati ispitivanja iskustava nastave prirodoslovnih predmeta provedenog u prvom dijelu istraživanja na cjelokupnoj populaciji učenika ovih škola pokazuju da se iskustva učenja i poučavanja fizike, kemije i biologije ne razlikuju značajno između dviju škola. Naime, pokazuje se da u obje škole učenici imaju vrlo malo prilika za samostalno eksperimentiranje, odnosno za samostalno osmišljavanje i provođenje eksperimenata. Tipična iskustva nastave prirodoslovnih predmeta uključuju gledanje demonstracijskih pokusa koje izvode nastavnici, ili ponekad rad u grupama, ali uz slijeđenje detaljnih uputa nastavnika o tome kako provesti pokuse. Kako se ispitane škole po nastavi prirodoslovnih predmeta značajno ne razlikuju, budući da uglavnom niti ne pripremaju učenike za zadatke koji zahtijevaju samostalno osmišljavanje i provođenje pokusa, može se pretpostaviti da školsko iskustvo učenika ne doprinosi značajno rezultatu na zadatku istraživačkog učenja kakav je korišten u ovom istraživanju.

Za provedbu istraživanja u školama osigurana je dozvola Ministarstva znanosti, obrazovanja i športa, kao i pristanak ravnateljica odabranih škola. Zbog specifičnosti istraživanja – velikih organizacijskih zahtjeva koji su bili postavljeni pred škole, kao i znatnog vremenskog opterećenja učenika – sudionika istraživanja, bilo je potrebno osigurati dobru suradnju sa školama, prije svega s ravnateljicama i stručnim suradnicama. Detaljno pismeno i usmeno informiranje o istraživanju, kao i dogovaranje o terminima dolaska istraživačice, uzorkovanju (kriterijima za odabir potencijalnih ispitanika) i rasporedu individualnih ispitivanja bili su neki od ključnih elemenata uspostavljanja kvalitetne suradnje istraživačice i škola.

Izbor učenika za sudjelovanje u istraživanju je proveden pomoću namjernog uzorkovanja koje se u literaturi naziva uzorkovanje maksimalnog razlikovanja (engl. *maximum variation sampling*) (Patton, 1990). Ovo uzorkovanje, kao i druge vrste namjernog uzorkovanja počiva na ideji «informativski bogatih» slučajeva koji mogu najbolje osvijetliti pojavu koja se ispituje, a predstavlja biranje ispitanika tako da odražavaju maksimalni varijabilitet koji postoji u populaciji na dimenzijama koje su ključne za predmet istraživanja (Patton, 1990). Iako ovo uzorkovanje, općenito govoreći, ne

---

<sup>7</sup> Jedna je škola bila locirana u središtu grada, dok se druga nalazila u Novom Zagrebu.

omogućuje generalizaciju rezultata s uzorka na populaciju u jednakom stupnju kao probabilističko, slučajno uzorkovanje, namjerno je uzorkovanje prikladno u situacijama u kojima je potrebno odabrati relativno malen uzorak ispitanika<sup>8</sup>. Izbor malog uzorka velike raznolikosti omogućuje prikupljanje: a) kvalitetnih i detaljnih nalaza o svakom slučaju, koji su korisni za dokumentiranje jedinstvenih karakteristika pojedinih slučajeva, kao i za opisivanje razlika koje postoje u skupini, kao i b) nalaza o zajedničkim obrascima koje dijele različiti slučajevi i koji svoju značajnost potvrđuju upravo u tome što su otkriveni u takvoj raznolikosti (Patton, 1990).

Uzorkovanje je u istraživanju, dakle, osmišljeno tako da odabrani učenici odražavaju širok raspon sposobnosti, postignuća i interesa relevantnih za rad na zadatku istraživačkog učenja. Kriteriji razlikovanja učenika na temelju kojih je provedeno uzorkovanje bili su sljedeći:

1. Spol učenika
2. Kognitivne sposobnosti učenika, odnosno inteligencija koja se u istraživanjima pokazuje značajnim prediktorom istraživačkog učenja (npr. Prins, 2002; Veenman, i sur., 2004; Prins i sur., 2006; Van der Stel i Veenman, 2008)
3. Interes za znanost

U nastavku je opisan proces odabira ispitanika u uzorak.

Krajem rujna 2008. godine svi su učenici osmih razreda u navedene dvije osnovne škole pristupili grupnom ispitivanju stavova prema prirodnim znanostima i iskustava s prirodoznanstvenim školskim predmetima, te testiranju inteligencije putem Testa nizova (Pogačnik, 1997). Ovo je ispitivanje imalo selekcijsku ulogu u izboru ispitanika za individualno ispitivanje, ali je služilo i kao dio istraživanja o statusu prirodoznanstvenog obrazovanja u hrvatskom osnovnoškolskom sustavu, koje nije predmet ovog rada.

Korišteni Test nizova, odnosno njegova kraća forma TN-10, je test fluidne inteligencije, prikladan kao brza i razmjerno gruba mjera opće intelektualne razine adolescenata i odraslih osoba (Pogačnik, 1997). Test ima 30 zadataka i na njemu se može postići maksimalno 30 bodova. Svaki se zadatak sastoji od 14 likova u nizu i 5 predloženih likova od koji treba izabrati onaj koji nastavlja niz. Vrijeme rada je ograničeno na 10 minuta. Na rezultat u testu utječe sposobnost otkrivanja odnosa i zakonitosti (induktivno rezoniranje),

---

<sup>8</sup> Kad je veličina uzorka mala, uzorci dobiveni uzorkovanjem maksimalnog razlikovanja mogu čak biti reprezentativniji od slučajnih uzoraka.



rezoniranje na neverbalnom materijalu, dobro radno pamćenje i brzina procesiranja informacija.

Tijekom grupnog ispitivanja prikupljeni su podaci od ukupno 114 učenika<sup>9</sup>. Rezultati na Testu nizova nisu se statistički značajno razlikovali između škola ( $t(112)=0,64$ ;  $p=,526$ ), ali su učenice u obje škole postigle statistički značajno bolje rezultate od učenika ( $t(112)=2,92$ ;  $p=,004$ ). Stoga je podjela učenika u skupine iznadprosječnih, prosječnih i ispodprosječnih na testu TN-10 provedena zasebno za učenice i učenike, bez obzira na to koju školu su pohađali (tablica 3). Navedene skupine su formirane na temelju statističkog kriterija – podjelom u tri skupine (tercile). Zbog grupiranja vrijednosti na pojedinim rezultatima, te skupine nisu sasvim podjednake veličine, posebice za mladiće.

*Tablica 3*  
Podjela učenika s obzirom na rezultat na Testu nizova TN-10

	Učenice		Učenici	
	Broj bodova	Broj učenica	Broj bodova	Broj učenika
Medijan	23	58	21	56
Ispodprosječni rezultat	0 - 20	19	0 – 18	18
Prosječni rezultat	21 – 24	22	19 – 22	25
Iznadprosječni rezultat	25 - 29	17	23 - 25	13

Također, učenici su podijeljeni na skupine učenika višeg i nižeg interesa za znanost, na temelju samoprocjena na ljestvici interesa prema znanosti. Ta je ljestvica interesa prema znanosti konstruirana za potrebe spomenutog istraživanja o statusu prirodnoznanstvenog obrazovanja u hrvatskom osnovnoškolskom sustavu. Ljestvica je Likertovog tipa od pet stupnjeva, a čini je šest tvrdnji: 1. Volim učiti o temama iz znanosti, 2. Zabavno mi je raditi pokuse, 3. Volim čitati o temama iz znanosti, 4. Volim gledati TV emisije o temama iz znanosti, 5. Želio bih biti znanstvenik, i 6. Želio bih raditi na radnom mjestu na kojem se koriste znanja iz znanosti. Faktorska analiza ove ljestvice metodom glavnih komponenata s Varimax rotacijom daje jednofaktorsko rješenje (eigen vrijednost veća od 1), pri čemu taj faktor objašnjava 54,0% varijance. Cronbach alpha ljestvice iznosi 0,82. Rezultat učenika na ljestvici se izražava kao zbroj procjena na pojedinim tvrdnjama.

Podjela učenika na one nižeg i višeg interesa za znanost je provedena po medijanu ( $C=19$ ) na uzorku učenika i učenica zajedno, s obzirom da se rezultat na faktoru interesa prema

<sup>9</sup> Budući da je prvo ispitivanje služilo u selekcijske svrhe, nije bilo anonimno. Jedna učenica nije željela sudjelovati u istraživanju. Jedan učenik (ili učenica) nije želio dati podatke o imenu i prezimenu pa je isključen iz obrade.

znanosti nije razlikovao statistički značajno s obzirom na spol učenika ( $t(112)=0,93$ ;  $p=,355$ ). 48 ispitanika (42,1%) je kategorizirano u skupinu nižeg, a 53 ispitanika (46,5%) u skupinu višeg interesa za znanost. Rezultati 13 učenika (11,4%) su se nalazili na centralnoj vrijednosti.

Izbor učenika za sudjelovanje u individualnom ispitivanju provela je istraživačica na temelju popisa svih učenika kojima su pridijeljene oznake pripadajućih skupina s obzirom na rezultat na Testu nizova i rezultat na ljestvici interesa prema znanosti. Izbor je proveden tako da se osigura jednak broj ispitanika oba spola, te podjednak broj učenika u skupini ispodprosječnog, prosječnog i iznadprosječnog rezultata na Testu nizova. Uzorkovanje je provedeno zasebno za svaku školu. U svakoj podskupini koja predstavlja kombinaciju spol X rezultat na Testu nizova, odabrani su učenici višeg i nižeg interesa za znanost. Ovisno o veličini pojedine podskupine spol X rezultat na Testu nizova X interes za znanost, odabran je jedan ili dva učenika.

Konačan odabir učenika za uzorak proveden je nakon konzultacija s nastavnicama biologije. One su bile detaljno informirane o cilju i sadržaju istraživanja te o istraživačkoj konceptualizaciji pojma istraživačkog učenja, a za pomoć pri odabiru ispitanika za individualno ispitivanje zamoljene su prvenstveno kako bi se kroz proces zajedničkog rada potaknuo njihov osjećaj uključenosti, osnažila njihova potpora istraživanju i ostvarila tješnja međusobna suradnja. S nastavnicama je raspravljen proces selekcije učenika, te su one dale svoje viđenje opravdanosti i valjanosti provedenih izbora, uspoređujući kategorizaciju temeljenu na učeničkim samoprocjenama s vlastitim procjenama učeničkih sposobnosti. Kako nije bilo osobitih primjedbi na provedeni odabir učenika u uzorak, planirani uzorak se smatrao konačnim.

Izabrano je 34 učenika<sup>10</sup> (30% od ukupnog broja učenika koji su pristupili grupnom ispitivanju), 16 učenika iz jedne i 18 učenika iz druge škole. Polovinu uzorka činile su učenice, a polovinu učenici.

U tablici 4 prikazana je raspodjela učenika uključenih u istraživanje s obzirom na korištene kriterije uzorkovanja<sup>11</sup>.

---

<sup>10</sup> U Prilogu u tablici 1 dat je prikaz karakteristika izabranih učenika s obzirom na kriterije uzorkovanja.

<sup>11</sup> Može se uočiti da su neke podskupine ispitanika brojčano zastupljenije od drugih. U podskupinama učenika prosječnog i iznadprosječnog rezultata na Testu nizova znatno je veći broj učenika u kategoriji višeg interesa za znanost, nego u kategoriji nižeg interesa za znanost. Kod učenica je ta podjela uravnotežena. Razlike u broju učenika u pojedinim podskupinama rezultat su opaženih spolnih razlika u povezanosti rezultata na Testu nizova i interesa za znanost na cijeloj skupini učenika dviju obuhvaćenih škola. Kod mladića je povezanost kognitivnih sposobnosti i interesa za znanost bila značajno veća nego kod djevojaka.

Tablica 4

Sastav uzorka učenika s obzirom na spol, rezultat na Testu nizova i rezultat na ljestvici interesa prema znanosti

	Učenicice			Učeniци		
	Rezultat na Testu nizova			Rezultat na Testu nizova		
	Ispodprosječan	Prosječan	Iznadprosječan	Ispodprosječan	Prosječan	Iznadprosječan
Niži interes za znanost	3	2	3	3	2	1
Viši interes za znanost	3	3	3	2	5	4
Ukupno	6	5	6	5	7	5

Provjereno je razlikuje li se skupina odabranih učenika od skupine učenika koji nisu odabrani. Rezultati pokazuju da među tim skupinama nema statistički značajne razlike, niti po rezultatu na Testu nizova ( $t(112)=0,88$ ,  $p=,379$ ), ni po procjeni na ljestvici interesa prema znanosti ( $t(112)=1,07$ ,  $p=,286$ ), što indicira da odabrani uzorak učenika dobro reprezentira skupinu učenika iz koje je izdvojen.

Planirana veličina uzorka od 34 učenika je određena razmatranjem nekoliko elemenata. S jedne strane, bilo je potrebno osigurati dovoljno velik uzorak učenika kako bi se mogli koristiti određeni statistički postupci za usporedbu unutar i između ispitanika. Osim toga, bilo je očekivano osipanje ispitanika tijekom istraživanja, budući da su u istraživanju pred ispitanike postavljeni relativno veliki zahtjevi (izostajanje s četiri školska sata u razdoblju od oko mjesec dana), odnosno da se tražio ponavljani rad na potpuno istom zadatku, što je moglo izazvati osjećaj dosade i želju za odustajanjem kod dijela ispitanika. S druge strane, bilo je potrebno zadržati se na relativno malom uzorku, kako bi se omogućilo dubinsko ispitivanje procesa promjena. Uz to, nije zanemarena niti činjenica da je istraživanje trebalo provesti u određenim, zadanim vremenskim okvirima i uz posjedovanje limitiranih ljudskih resursa.

Nakon određivanja uzorka i odabira pojedinih učenika, zatražen je pristanak učenika, odnosno pristanak roditelja za sudjelovanje učenika u istraživanju.

Roditelji su bili pismeno obaviješteni o sadržaju i cilju istraživanja i o angažmanu njihovog djeteta u istraživanju, te su biti zamoljeni da svojim potpisom iskažu pristanak na sudjelovanje djeteta u istraživanju. U skladu s Etičkim kodeksom istraživanja s djecom (Ajduković i Kolesarić, 2003), u pismu je bila zajamčena povjerljivost prikupljenih podataka i anonimnost učenika u izvještavanju o rezultatima istraživanja. Pisma su

Npr. unutar kategorije ispitanika s iznadprosječnim rezultatom na Testu nizova, u kategoriju višeg interesa za znanost kategorizirano je 47% djevojaka, a 77% mladića.

izabranim učenicima predale nastavnice biologije, uz zamolbu za sudjelovanjem u istraživanju. Roditelji dvije učenice nisu dali pristanak za sudjelovanje, pa su te učenice zamijenjene drugim učenicama podjednakih karakteristika s obzirom na rezultat na Testu nizova i iskazani interes prema prirodnim znanostima.

Istraživanje je, dakle, započelo uz planirani broj od 34 ispitanika. Međutim, za sva su četiri mjerenja<sup>12</sup> prikupljeni podaci 33 ispitanika. Jedan je ispitanik već u prvoj situaciji učenja postigao potpuno rješenje zadatka, uz primjenu valjanih eksperimentalnih i inferencijalnih strategija<sup>13</sup>. Nakon drugog mjerenja, u kojem je taj ispitanik jednako uspješno radio, rečeno mu je da ne treba pristupiti sljedećim mjerenjima. Rezultati tog ispitanika su uključeni u analize metastrateškog i strateškog djelovanja, tako da su podaci (mjere uspješnosti rada na zadatku) koji nedostaju u trećem i četvrtom mjerenju zamijenjeni podacima iz drugog mjerenja. Podaci koji opisuju pristup radu, ali nisu mjere uspješnosti (npr. o broju napravljenih eksperimenata), kao i motivacijske i emocionalne procjene tretirane su kao nepostojeći podaci.

Do osipanja drugih ispitanika tijekom istraživanja nije došlo. Tome su pridonijele učestale obavijesti, podsjećanja učenika i prilagođavanje vremena održavanja ispitivanja potrebama učenika i zahtjevima nastavnika.

Na kraju istraživanja ispitanicima su podijeljene zahvalnice<sup>14</sup>, te mali poklon.

Nakon završetka individualnih ispitivanja sa svim učenicima unutar pojedine škole, svi sudionici istraživanja dobili su pismeni opis točnog rješenja zadatka, cilja zadatka, kao i primjer valjanog pristupa eksperimentiranju<sup>15</sup>. Na primjeru zadatka korištenog u istraživanju prikazano je korištenje strategije kontrole varijabli, te su učenici upućeni na nužnost korištenja ove strategije pri zaključivanju o utjecaju pojedinih čimbenika na rezultat.

---

<sup>12</sup> Za jednokratni rad na zadatku u radu se koristi termin „mjerenje“.

<sup>13</sup> Svi su ostali učenici, u prvom susretu sa zadatkom istraživačkog učenja pokazivali potpunu ili djelomičnu prisutnost nevaljanih strategija eksperimentiranja i zaključivanja, te da su kroz rad na zadatku, sporije ili brže napredovali prema valjanijim istraživačkim postupcima.

<sup>14</sup> U Prilogu.

<sup>15</sup> U Prilogu.

## 4.2. Opis zadatka

Istraživačko učenje je ispitivano pomoću zadatka u računalno podržanom okruženju. Korišten je program Flexible Inquiry Learning Environment FILE (Hulshof, Wilhelm, Beishuizen, Van Rijn, 2005; Wilhelm i sur., 2005), koji je preveden i prilagođen za potrebe istraživanja. Program FILE je odabran kao istraživačka platforma, zato što omogućuje prezentaciju relativno jednostavnog multivarijatnog kauzalnog modela kao istraživačkog zadatka, a ujedno osigurava *online* praćenje procesa učenja.

Učenik radi na zadatku u FILE-u tako da provodi eksperimente. Učeniku su u zadatku prikazane različite kategorije ulaznih (nezavisnih) varijabli. Učenik osmišljava eksperimente birajući i mijenjajući vrijednosti ulaznih varijabli i promatra rezultirajuću vrijednost izlazne (zavisne) varijable. Provodeći takve eksperimente i promatrajući rezultate promjena u vrijednostima zavisne varijable ovisno o vrijednostima nezavisnih varijabli, učenik je u situaciji u kojoj može zaključivati o vezama između nezavisnih i zavisne varijable. Zadatak učenika je istražiti u kakvom su odnosu nezavisne varijable sa zavisnom, odnosno otkriti utječe li i kako pojedina nezavisna varijabla na zavisnu varijablu.

Zadatak sadrži pet nezavisnih varijabli, od čega četiri varijable s dvije kategorije i jednu varijablu s tri kategorije (razine). Struktura zadatka je takva da dvije nezavisne varijable nemaju učinak na zavisnu varijablu. Jedna nezavisna varijabla je u nelinearnom odnosu sa zavisnom varijablom, pri čemu dvije razine te nezavisne varijable rezultiraju istim učinkom u zavisnoj varijabli, dok jedna razina daje drugačiji učinak. Dvije varijable imaju glavni učinak na zavisnu varijablu, ali su međusobno u interakciji. Na jednoj razini nezavisne varijable X, nema razlike u učinku s obzirom na vrijednosti nezavisne varijable Y, dok se na drugoj razini nezavisne varijable X učinak razlikuje s obzirom na razine nezavisne varijable Y. Zadaci ovakve strukture (istog broja varijabli i istovjetne vrste odnosa varijabli) korišteni su u većini istraživanja koja ispituju istraživačko učenje na učenicima osnovnoškolske dobi (npr. Kuhn i sur., 1995, 2000; Kuhn i Pearsall, 1998; Keselman, 2003; Veenman i sur., 2004; Veenman i Spaans, 2005; Wilhelm i Beishuizen, 2003).

U istraživanju je korišten zadatak iz područja ekologije, koje se u školi poučava u okvirima predmeta Priroda i Biologija. Sadržaj zadatka je osmišljen isključivo za potrebe istraživanja. Zadatak je okvirno temeljen na važećem nastavnom programu Prirode, s

obzirom da koristi temu «Korist od šuma, onečišćenje i zaštita» koja se obrađuje u šestom razredu (MZOŠ, 2006). Ne pretpostavlja se, međutim, da je tema u nastavi obrađivana na istraživački način, slično zadatku u FILE-u, niti da su tematski obrađeni utjecaji varijabli ispitivanih u tom istraživačkom zadatku. Odabirom sadržaja zadatka koji se tematski oslanja na nastavne sadržaje koje su učenici već obradili željelo se postići da sadržaj zadatka u FILE-u bude učenicima barem donekle poznat, odnosno osigurati da oni već imaju neka formirana očekivanja, teorije<sup>16</sup> ili znanja o ispitivanim varijablama i njihovim učincima.

Zadatak se bavi utjecajem različitih čimbenika na uništenje šuma. Zavisna varijabla je definirana kao stupanj uništenja šuma, na ljestvici od pet stupnjeva, gdje je 1 označavalo vrlo mali stupanj uništenja, 5 vrlo veliki stupanj uništenja šuma.

Odabir nezavisnih varijabli za zadatak temeljen je na rezultatima predispitivanja provedenog u proljeće 2008. godine na uzorku od 26 učenika osmih razreda jedne osnovne škole koja nije sudjelovala u glavnom istraživanju. U upitniku<sup>17</sup>, koji su ispunjavali ti učenici u predispitivanju, bilo je navedeno 36 čimbenika koji mogu (ili ne moraju) imati utjecaj na uništenje šuma. Ti su čimbenici izabrani na temelju pregleda literature iz područja zaštite šuma pronađene na internetu, analize udžbenika iz Prirode za šesti razred i konzultacija s jednim stručnjakom iz područja šumarstva. Učenici su za svaki čimbenik trebali označiti, ima li on ili nema, po njihovom mišljenju, utjecaj na uništenje šuma, te odrediti smjer utjecaja za one čimbenike za koje su odredili da postoji utjecaj. To su učinili tako da su od dvije ponuđene kategorije za pojedinu varijable (npr. blizu ili daleko od prometnica za varijablu 'udaljenost od prometnica'), zaokružili onu kategoriju uz koju su smatrali da je prisutan veći stupanj uništenja šuma. Rezultati predispitivanja su pokazali da su učenici većinu ponuđenih čimbenika smatrali uzročno povezanim sa ishodom (20 čimbenika), a tek su za manji dio čimbenika (sedam) vjerovali da nemaju utjecaj na uništenje šuma. Za devet čimbenika nije nađeno slaganje učenika o tome imaju li ti čimbenici ili nemaju utjecaj na uništenje šuma, odnosno u kojem smjeru se njihov utjecaj očituje. Dakako, pri biranju varijabli koje će biti uključene u zadatak u FILE-u pokušalo se izdvojiti one varijable za koje učenici većinom imaju ista očekivanja, ali je njihov izbor bio znatno lakši unutar kategorije kauzalnih, nego unutar kategorije nekauzalnih čimbenika.

---

<sup>16</sup> Pojam “teorije” koji se koristi u istraživanju nije istovjetan pojmu teorije koji postoji u znanosti. Pod “teorijom” se podrazumijeva neka mentalna reprezentacija nekog objekta ili pojave koja može biti različitog stupnja složenosti, organiziranosti i elaboriranosti.

<sup>17</sup> Upitnik iz predispitivanja se nalazi u Prilogu.

Cilj je bio konstruirati zadatak tako da budu uključene dvije varijable za koje učenici očekuju da su nekauzalne, odnosno nepovezane s ishodom, od kojih jedna u zadatku djeluje u skladu s učeničkim očekivanjem (potvrđuje se njezina nekauzalnost), a druga djeluje suprotno očekivanjima (ne potvrđuje se nekauzalna teorija). Također, cilj je bio uključiti i dvije varijable za koje učenici očekuju da su kauzalne, od kojih je kod jedne u zadatku stvarno prisutan kauzalni učinak (potvrđuje se kauzalnost), a kod jedne zapravo nema učinka (kauzalnost se ne potvrđuje). Na taj se način željelo uključiti i varijable koje djeluju u skladu s učeničkim očekivanjima, i varijable koje djeluju protivno njihovim prethodnim teorijama, kako bi zadatak bio pogodan za ispitivanje procesa koordinacije teorija i nalaza.

Osim što su na izbor nezavisnih varijabli za zadatak utjecali uvidi u učenička očekivanja o utjecaju pojedinih čimbenika na uništenje šuma, vodilo se računa o tome da odnosi među varijablama u modelu zadatka budu realni, odnosno temeljeni na mogućim pojavama. Poseban je problem predstavljalo osmišljavanje vjerojatnog i smislenog interakcijskog učinka.

Kako bi se utvrdilo zadovoljava li zadatak te postavljene zahtjeve, provedeno je njegovo predispitivanje u FILE-u. U tom je predispitivanju sudjelovalo šest učenika na kraju sedmog razreda u istoj osnovnoj školi u kojoj je provedeno predispitivanje s ciljem odabira nezavisnih varijabli za zadatak. Kroz opažanje rada tih učenika na zadatku u programu FILE u dvije situacije učenja, utvrđena je težinska primjerenost i plauzibilnost postavljenog kauzalnog modela. Ustanovljeno je da je za učenike otkrivanje predloženog kauzalnog modela izazovan, srednje težak zadatak. Učenici su procjenjivali zadatak novim, zanimljivim i različitim od zadataka s kojima se uobičajeno susreću u okviru nastave prirodoslovnih predmeta. U situaciju učenja učenici su uglavnom ulazili s oblikovanim očekivanjima o odnosima nezavisnih i zavisne varijable. Odnose među varijablama prikazane u zadatku učenici su smatrali mogućima i interpretabilnima.

Rezultati predispitivanja su pokazali upotrebljivost predloženog zadatka za ispitivanje istraživačkog učenja, pa je konačno određeno da nezavisne varijable u zadatku budu sljedeće:

1. Vrsta drveća u šumi (bjelogorično ili crnogorično)
2. Konfiguracija tla (nizinski ili brežuljkasti pojas)
3. Udaljenost od naselja (blizu ili daleko od naselja)

4. Učestalost pojave kiselih kiša (rijetko, često, vrlo često) i
5. Pojava nametnika (nema ili ima nametnika).

Prema modelu zadatka, konfiguracija tla i udaljenost od naselja nisu kauzalne varijable, odnosno nemaju utjecaj na to koliko su šume uništene. Pojava kiselih kiša je u nelinearnom odnosu sa stupnjem uništenja šuma. Česta i vrlo česta pojava kiselih kiša međusobno se ne razlikuje u svojem učinku na stupanj uništenja šuma (koji je visok), a razlikuju se od rezultata koji je prisutan uz rijetku pojavu kiselih kiša. Vrsta drveća u šumi ima glavni učinak, budući da su bjelogorične šume uništenije od crnogoričnih, ali je ova varijabla u interakciji s pojavom nametnika. Crnogorične i bjelogorične šume ne razlikuju se po učinku na stupanj uništenja šuma u situaciji kad nema nametnika. Kad postoje nametnici, bjelogorične šume su podložnije uništenju od crnogoričnih. Glavni učinak pojave nametnika također postoji, budući da su šume u kojima ima nametnika uništenije od šuma u kojima nema nametnika.

Model zadatka je prikazan u tablici 5. Navedeni su stupnjevi uništenja šume ovisno o kombinaciji relevantnih tj. kauzalnih nezavisnih varijabli.

*Tablica 5*

Prikaz modela zadatka: stupanj uništenja šuma (najmanji stupanj (1) do najviši stupanj (5)) ovisno o kauzalnim nezavisnim varijablama

	Ima nametnika		Nema nametnika	
	Bjelogorica	Crnogorica	Bjelogorica	Crnogorica
Rijetko padaju kisele kiše	3	2	1	1
Često padaju kisele kiše	5	4	3	3
Vrlo često padaju kisele kiše	5	4	3	3

U tablici 6 su nezavisne varijable korištene u zadatku razvrstane u dvodimenzionalnu matricu kauzalnosti. Jednu dimenziju te matrice čine početne teorije učenika (iz predispozicija), a drugu model zadatka.



*Tablica 6*  
Dominantne teorije učenika iz predispitivanja X model zadatka

		Teorije učenika o utjecaju varijabli	
		Kauzalna teorija	Nekauzalna teorija
Model zadatka	Nekauzalne varijable	Udaljenost od naselja	Konfiguracija tla
	Kauzalne varijable	Pojava nametnika/ Učestalost pojave kiselih kiša <sup>18</sup>	Vrsta drveća <sup>19</sup>

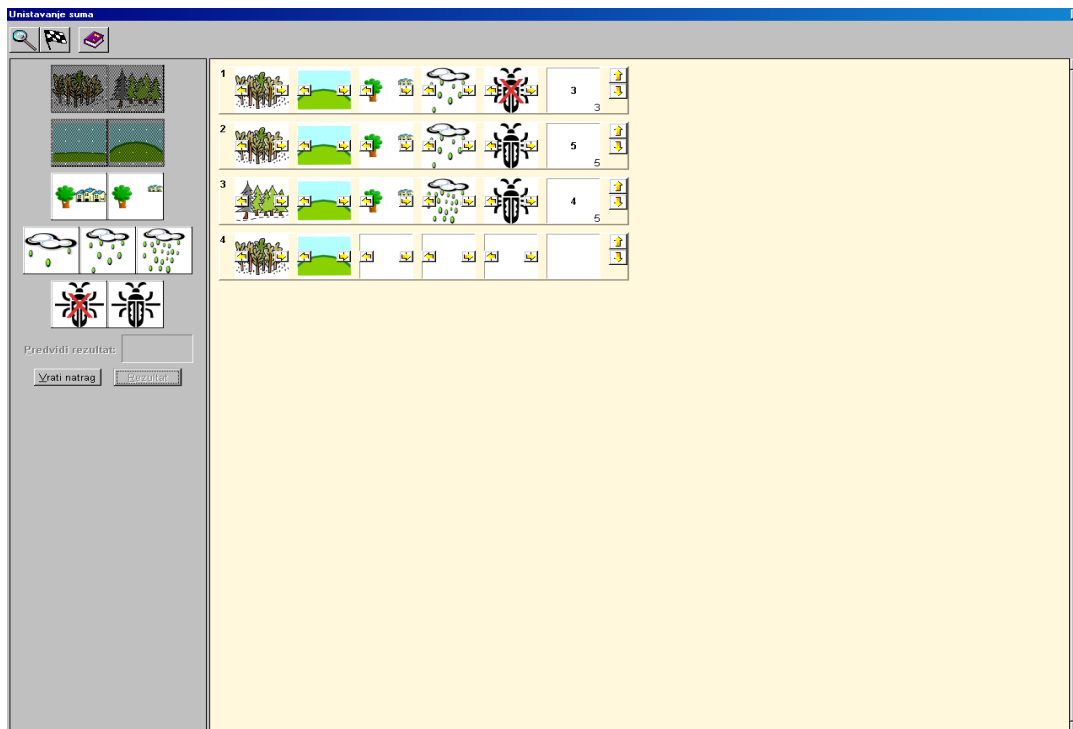
Odabir varijabli u model zadatka temeljio se na većinskom mišljenju učenika uključenih u predispitivanje o odnosima nezavisnih i zavisne varijable. Zadatak je osmišljen tako da aproksimira idealnu situaciju u kojoj se prethodne (ne)kauzalne teorije većine učenika mogu i potvrditi i opovrgnuti. Međutim, već je predispitivanje pokazalo da je teško pronaći varijable koje svi učenici smatraju nekauzalnima, odnosno da je posebno teško osmisliti varijable koje učenici prvotno smatraju nekauzalnom, a za koje može postojati plauzibilan kauzalni učinak. Stoga se obrada i analiza rezultata ne temelji na većinskom mišljenju učenika, već se u obzir uzimaju stvarne, izrečene teorije koje o odnosima među varijablama imaju pojedini ispitanici u pojedinim fazama rada na zadatku.

<sup>18</sup> Učenici očekuju da češće padanje kiselih kiša donosi veći stupanj uništenja šuma, a model zadatka također uključuje tu varijablu kao kauzalnu. Međutim, nelinearnost odnosa (nepostojanje razlike između razine čestog i vrlo čestog padanja kiselih kiša) pruža uvjete za djelomičnu potvrdu i djelomično opovrgavanje učeničkih prethodnih kauzalnih teorija o utjecaju tog čimbenika.

<sup>19</sup> Učenici iz predispitivanja nisu bili suglasni o tome utječe li vrsta drveća na uništenje šuma ili ne. Polovina učenika je smatrala taj čimbenik kauzalnim, a polovina nekauzalnim. Učenici koji su smatrali da je vrsta drveća relevantan čimbenik, nisu bili usklađeni niti u tome kakav su utjecaj očekivali – dok je znatan dio tih učenika smatrao da je bjelogorica podložnija uništenju od crnogorice, drugi dio je mislio suprotno. Kako je u zadatku prisutan glavni učinak vrste drveća, zadatak predstavlja situaciju potvrde očekivanja za manji dio učenika, a situaciju opovrgavanja za veći dio učenika iz predispitivanja.

### 4.3. Opis sučelja i postupka rada u programu FILE

Prikaz sučelja programa dat je na slici 2.



Slika 2. Prikaz sučelja FILE-a

Nezavisne varijable odnosno njihove kategorije i razine prikazane su kao zasebne sličice na lijevoj strani prozora. U svakom retku koji predstavlja jednu nezavisnu varijablu učenik treba izabrati jednu sličicu (kategoriju nezavisne varijable) tako da na nju klikne. Izabrane sličice učenik može odmah vidjeti na desnoj strani prozora.

Eksperiment obuhvaća aktivnost u kojoj učenik odabere za svaku nezavisnu varijablu jednu kategoriju (sličicu). Učenik sam odabire koje sličice će izabrati i kojim redoslijedom. Ako izabere sličice, ali se predomisli i želi neku promijeniti, može to učiniti klikom na polje *vрати natrag*.

Nakon toga, kad učenik izabere vrijednosti svih pet nezavisnih varijabli, u polju *predvidi rezultat* učenik radi predviđanje rezultata eksperimenata, odabirući razinu zavisne varijable koju očekuje za napravljenu kombinaciju kategorija nezavisnih varijabli. Učenik bira vrijednost zavisne varijable iz ponuđenih odgovora (1 – 5), a moguć je i odgovor ? koji označava nemogućnost predviđanja, odnosno odgovor „Ne mogu odlučiti, ne znam“.

Nakon predviđanja, i odluke da više ništa ne želi mijenjati u odabiru sličica, učenik klikne na polje *rezultat*.

Tada se u prozoru, na kraju retka eksperimenta na kojem je učenik upravo radio, pojavi novo polje na kojem piše stvarni rezultat u zavisnoj varijabli (središnje mjesto u polju), kao i učenikov predviđen rezultat (dolje desno u istom polju).

Jednom kad učenik klikne na *rezultat*, eksperiment postaje fiksiran i više se ne može mijenjati. Učenik tad kreće s radom na sljedećem eksperimentu.

Već napravljeni eksperimenti ostaju vidljivi kako se pojavljuju novi, a maksimalno se u prozoru može vidjeti četiri eksperimenata. Ako učenik želi vidjeti napravljene eksperimente koji su već nestali s prozora, može se pomicati mišem gore-dolje (koristiti tzv. «*scroll*») i tako vidjeti «stare» eksperimente.

Također, učenik može napraviti selekciju napravljenih eksperimenata. Ukoliko želi neke eksperimente izdvojiti i usporediti, može kliknuti na odabrane eksperimente i prikazati ih u posebnom prozoru, tako da klikne na *povećalo* koje se nalazi u gornjem lijevom kutu prozora.

Nadalje, učenik može organizirati postojeće eksperimente promjenom njihova redoslijeda. Time si može olakšati usporedbu pojedinih eksperimenata. Učenik može mijenjati i redoslijed varijabli unutar pojedinog eksperimenta. Redoslijed napravljenih eksperimenata i sličica u eksperimentima može se promijeniti klikanjem na male žute strelice koje se nalaze uz sličice. Strelice unutar eksperimenta pomiču sličice lijevo-desno, a strelice na kraju reda pomiču eksperiment gore-dolje.

Ukoliko, pak, za vrijeme rada na zadatku, učenik želi ponovno pročitati upute za rad, može kliknuti na *knjigu* koja se nalazi u gornjem lijevom kutu prozora.

Program FILE omogućuje dokumentiranje svih radnji učenika u računalni automatski zapisnik (*engl. log file*). Bilježi se vrijeme provođenja eksperimenata, odabir kategorija nezavisnih varijabli, predviđeni rezultat, ponovno čitanje upute, kao i aktivnosti pomicanja gore-dolje, reorganiziranja i selekcije eksperimenata.

Predtestiranjem na šest učenika sedmih razreda provjereno je koliko je program FILE jednostavan za korištenje, kako funkcionira njegov prijevod, te koliko je vremensko trajanje jednog mjerenja. Utvrđeno je da program zadovoljava u svim ovim elementima. Jedino su, radi veće razumljivosti, napravljene neke male preinake u uputi za rad.

#### 4.4. Tijek istraživanja i postupak

Istraživanje je provedeno u jesen 2008. godine. Nakon selekcijskog postupka i izbora ispitanika, istraživanje je provedeno u dvije faze:

1. Grupna demonstracija programa FILE i ispitivanje metakognitivnog znanja
2. Individualno ispitivanje istraživačkog učenja korištenjem FILE-a u četiri situacije učenja (mjerjenja)

U nastavku su obje faze istraživanja detaljno opisane.

##### 4.4.1. Grupni sastanak

S učenicima koji su pristali na sudjelovanje u istraživanju održan je uvodni grupni sastanak. Na sastanku su učenici ukratko upoznati sa svrhom i rasporedom istraživanja. Učenicima je predstavljeno da se istražuje kako učenici osnovnih škola rješavaju jedan istraživački zadatak na računalu, te da im sudjelovanje u istraživanju omogućava uvježbavanje vještina mišljenja.

Učenicima je pokazan program FILE. U demonstracijske svrhe korišten je zadatak o dječaku Petru koji kasni u školu, a koji je korišten u istraživanjima autora programa (npr. Hulshof, 2001; Wilhelm i Beishuizen, 2003). Taj je zadatak po strukturi potpuno jednak zadatku o uništenju šuma korištenom u ovom istraživanju.

Učenicima je pročitana sljedeći tekst koji uvodi u zadatak «Petar»:

Petar je dječak koji često kasni u školu. Nekad zakasni 5 minuta, nekad 10 ili 15, a nekad čak 20 minuta. Tek ponekad stiže bez kašnjenja. Nakon što ga je razrednica više puta upozorila i rekla mu da riješi taj problem, Petar je odlučio prestati s tom navikom. Razmišljajući o tome što napraviti, zaključio je da prvo mora otkriti zašto je dosad kasnio. Napravio je popis stvari koje bi mogle utjecati na to koliko minuta kasni u školu:

Zapisao je sljedeće:

- vrsta bicikla koji vozi (trkaći ili gradski)
- jede li doručak (sendvič) kod kuće ili putem kad se vozi
- način na koji se vozi (u društvu druge djece, sam - normalnom brzinom, sam - što brže može)
- teret koji nosi u torbi (sve što mu može zatrebati ili samo nužne bilježnice)
- vrsta obuće koju nosi (cipele ili tenisice)

Po Petrovom mišljenju, svaka od ovih stvari bi mogla imati veze s tim kad on stiže u školu.

Napravljen je računalni program kojim se želi pomoći Petru to otkriti. Želimo vidjeti koliko minuta Petar kasni u školu ovisno o tome što je toga dana odabrao od navedenih stvari.

Učenicima je nakon toga prikazan rad u FILE-u. Pročitana im je uputa za rad na zadatku, te su provedena dva eksperimenta (nekontroliranom usporedbom). Učenicima je rečeno da se nakon rada na zadatku učenike ispituje o tome što su zaključili o tome kakav je odnos pojedinih čimbenika prikazanih u zadatku i vremena dolaska u školu, odnosno ispituje ih se što ima, a što nema utjecaj na to koliko Petar kasni u školu. Učenicima su prikazane i objašnjene sve mogućnosti programa (selekcija eksperimenata, organizacija eksperimenata, ponovno čitanje upute).

Pri prikazu programa FILE, vodilo se računa o tome da se učenicima detaljno prikaže procedura rada na zadatku, ali bez sugeriranja ispravnih ili poželjnih strategija rada na zadatku. Učenicima je pružena i mogućnost postavljanja pitanja, ali je odgovarano samo na ona pitanja koja su se odnosila na postupak rada na zadatku, a ne i na pitanja o preferiranim ili mogućim pristupima rada na zadatku.

Nakon prikaza rada na zadatku, učenici su ispunili prvi upitnik metakognitivnog znanja. Prosječno trajanje ispunjavanja upitnika bilo je oko 15 minuta.

#### ***4.4.2. Individualno ispitivanje u programu FILE***

Primjena FILE-a (zadatka o uništenju šuma) je provedena individualno<sup>20</sup>. Rad učenika na zadatku je sniman putem web kamere te digitalnim diktafonom<sup>21</sup> (uz pristanak ispitanika). Računalo je bilježilo aktivnosti učenika za vrijeme rada na zadatku.

Svaki učenik je u programu FILE, na zadatku o uništenju šuma, radio četiri puta, u prosječnom razmaku između pojedinih mjerenja od 7,8 dana. Mjerenja su se odvijala tijekom nastave, na satovima različitih predmeta. Tijekom jednog školskog sata ispitivan je po jedan učenik.

Ispitivanja je većim dijelom vodila glavna istraživačica (75%), a dijelom pomoćna istraživačica<sup>22</sup> (25%), kako bi se, omogućavanjem paralelnog ispitivanja, postigla željena brzina odvijanja istraživanja i osiguralo ispitivanje pojedinih učenika u podjednakim razmacima između pojedinih mjerenja.

---

<sup>20</sup> Mjerenja su se odvijala u školskoj knjižnici i u kabinetu stručne suradnice, čime je većinom osigurano nesmetano odvijanje ispitivanja.

<sup>21</sup> Dvostruko snimanje je primijenjeno kako bi se potpuno osigurao zapis.

<sup>22</sup> Pomoćna istraživačica je bila prof. psihologije. Za uvođenje u ulogu pomoćne istraživačice proveden je trening, koji je uključivao rad u FILE-u u svojstvu ispitanice, opažanje nekoliko „stvarnih” mjerenja s učenicima te vođenje jednog mjerenja u predispitivanju uz pratnju glavne istraživačice.

Na početku prvog mjerenja učeniku je dat sljedeći opis zadatka i uputa za rad<sup>23</sup>.

### OPIS PROBLEMA (ZADATKA):

Grupa stručnjaka i istraživača radi na projektu zaštite šuma. Žele otkriti što utječe na uništavanje šuma u njihovom podneblju, te na temelju toga predložiti najdjelotvornije mjere za njihovo očuvanje.

Prvo su obišli nekoliko šuma i ispitali stupanj njihovog uništenja. Neke su šume bile manje, a neke više uništene. Odredili su da postoji 5 stupnjeva uništenja šuma - gdje 1 označava vrlo nizak stupanj uništenosti šuma, 2 označava nizak, 3 srednji, 4 visok, a 5 vrlo visok stupanj uništenosti šuma.


Kako bi otkrili što utječe na uništenje šuma, istraživači su priredili popis čimbenika koji bi mogli utjecati na to koliko su šume uništene.

Zapisali su sljedeće:

- Vrsta drveća u šumi: *bjelogorično* ili *crnogorično*



- Konfiguracija tla: *nizinski pojas* ili *brežuljkasti pojas*




- Udaljenost šume od naselja: *blizu naselja* ili *daleko od naselja*



- Učestalost pojave kiselih kiša: *kisele kiše padaju rijetko* ili *često* ili *vrlo često*



- Pojava štetnika (nametnika): u šumi *nema štetnika* ili *ima štetnika*



Po mišljenju istraživača, svaka od ovih stvari mogla bi imati veze s tim koliko su šume uništene.

Ovim zadatkom želi se pomoći istraživačima to otkriti. Treba otkriti stupanj uništenja šuma ovisno o tome koji su od navedenih čimbenika prisutni, odnosno pronaći što ima, a što nema utjecaj na uništenje šuma!

<sup>23</sup> Uputa za rad nalazi se u Prilogu.

Učeniku je rečeno da sam bira kako i kojim redom će provoditi pojedine eksperimente, te da sam određuje koliko će eksperimenata ukupno napraviti. Također mu je rečeno da će na kraju svakog mjerenja (na kraju školskog sata) biti pitan o tome kakav učinak svaka nezavisna varijabla ima na zavisnu varijablu, odnosno „o tome što od prikazanih čimbenika ima, a što nema utjecaj na uništenje šuma“.

Prije početka rada na zadatku, učenik je odgovarao na pitanja iz upitnika o prospektivnom metakognitivnom doživljaju, emocionalnom stanju i motivaciji za rad na zadatku, te je proveden prvi razgovor o početnim teorijama učenika o učinku pojedinih čimbenika na uništenje šuma. Prvo je postavljeno pitanje: *Što misliš koji čimbenici nemaju utjecaja?*, te je učenik zamoljen da obrazloži svoj odgovor. Zatim su postavljena sljedeća pitanja o očekivanim učincima svih ostalih varijabli: *Očekuješ li da čimbenik X ima utjecaj na stupanj uništenja šuma? Ako da, kakav utjecaj očekuješ?* Od ispitanika je traženo i objašnjenje odgovora pomoću pitanja: *Zašto očekuješ da čimbenik X ima (takav) utjecaj na rezultat?*

Nakon razgovora o početnim teorijama učenika, učenik je pristupio radu na zadatku. Neposredno prije početka rada, učeniku je rečeno da će tijekom rada biti ispitivan o tome što radi i kako se osjeća. Učenik je upućen da misli naglas i kazuje kako bira kategorije nezavisnih varijabli, putem sljedeće upute: *Molim te pokušaj pri radu govoriti naglas o tome kako radiš, kako biraš pokuse i što pritom razmišljaš.* Tijekom rada na zadatku, ukoliko bi učenik prestao misliti naglas, istraživačica ga je poticala pitanjima ili opaskom «*Molim te pokušaj govoriti naglas*».

Također, učeniku je dana mogućnost da zapisuje nešto što želi (npr. zaključke) na prazan papir pripremljen u tu svrhu.

Prije svakog eksperimenta učenik je pitan o planu/ namjeri provedbe tog eksperimenta (*Što ćeš sad napraviti/ istražiti?* ili *Što želiš saznati u ovom eksperimentu? Kako to namjeravaš saznati?*), te o predviđanju i hipotezi (*Što želiš dobiti ovim eksperimentom?* ili *Što očekuješ da ćeš otkriti?* ili *Što misliš da će biti ishod ovog eksperimenta?*).

Kad je učenik završio pojedini eksperiment, pitan je za zaključak (*Što si saznao/ dobio/ otkrio?* ili *Što možeš zaključiti o učinku čimbenika na temelju provedenog/ provedenih eksperimenata?* ili *Što misliš o tome kako je ispalo?*). Učenik je nadalje pitan za objašnjenje svojeg zaključka, ako je bilo potrebno, pomoću pitanja: *Kako si to zaključio (na temelju čega)?* ili *Kako znaš da X ima/ nema utjecaj?*

Nakon svakog četvrtog<sup>24</sup> eksperimenta učenik je prekinut u radu, te je odgovorio na nekoliko pitanja o motivaciji, emocionalnom stanju i metakognitivnom doživljaju zadatka.

Učenik je sam određivao kad će završiti s radom. Iznimke su predstavljali slučajevi kad je rad u FILE-u trajao više od 35 minuta<sup>25</sup>, ili kad je učenik napravio manje od 10 eksperimenata<sup>26</sup>, kad se od njega tražilo da nastavi s radom i provede dodatne eksperimente. Učeniku je rečeno: „*Molim te pokušaj napraviti još eksperimenata!*“

Kad je učenik završio s radom na zadatku, program je zaustavljen, a istraživačica je ukratko tražila od učenika opis njegovog doživljaja i pristupa radu na zadatku. Također, učenik je odgovarao na pitanja u upitniku o retrospektivnom metakognitivnom doživljaju, motivaciji i emocionalnom stanju. Na kraju je proveden razgovor o teorijama tj. o učincima nezavisnih varijabli na zavisnu koje je učenik otkrio tijekom ispitivanja. Za svaku nezavisnu varijablu, učeniku su postavljena sljedeća pitanja: *Utječe li ili ne čimbenik X na stupanj uništenja šuma?* (ili *Kakva je razlika u stupnju uništenja šuma ovisno o tome je li šuma.....ili .....?*) te *Kakav utjecaj ima čimbenik X na rezultat?* Od učenika je također traženo da izrazi stupanj uvjerenosti u točnost tvrdnje o utjecaju čimbenika X.

Procedure pojedinih mjerenja (prvog do četvrtog) su se ponešto razlikovale. U drugom do četvrtom mjerenju opis zadatka i uputa za rad na zadatku učenicima su čitani samo na njihov zahtjev. Međutim, u svakom su mjerenju učenici upućeni na mogućnosti programa (selekcija, organizacija eksperimenata, pomicanje u prozoru gore-dolje) kao i na mogućnost korištenja zapisnika.

U trećem je susretu, u svrhu održavanja motivacije učenika za sudjelovanje u istraživanju i «razbijanja monotonije», poslije rada u FILE-u dodan kratki petminutni razgovor o učenikovim stavovima o predmetima koje uče u školi, kao i o nastavku školovanja. Razgovor se vodio o omiljenim predmetima, pozitivnim i negativnim aspektima prirodoslovnih predmeta i nastave, idealnom satu iz prirodoslovnih znanosti, te o izboru srednje škole.

Četvrto, posljednje mjerenje je završilo ispunjavanjem završnog upitnika. U sklopu završnog upitnika primijenjen je drugi upitnik metakognitivnog znanja. Osim toga,

---

<sup>24</sup> Razmak između pojedinih mjerenja tekućih motivacijskih i metakognitivnih procesa od četiri eksperimenata je određen u namjeri minimalnog ometanja ispitanika u radu, na temelju činjenice da su četiri eksperimenata dovoljna za otkrivanje interakcijskog učinka.

<sup>25</sup> Samo je jedan ispitanik u jednom mjerenju dosegao taj vremenski limit rada u FILE-u.

<sup>26</sup> Deset eksperimenata je minimalni broj eksperimenata potreban za otkrivanje svih učinaka u postavljenom zadatku.



ponovno je ispitivano znanje učenika o odnosu nezavisnih i zavisne varijable u zadatku o uništavanju šuma, kao i njihov završni stav o sudjelovanju u istraživanju i vlastitoj uspješnosti, što je popraćeno atribucijskim procjenama.

#### **4.5. Mjerni instrumenti i korištene mjere**

Za potrebe istraživanja razvijeni su različiti mjerni instrumenti i korišteni različiti postupci za prikupljanje podataka o složenim i dinamičnim procesima istraživačkog učenja. U nastavku su opisani ti instrumenti i postupci, a prikazane su i mjere koje su derivirane iz sirovih podataka.

Pojmovni okvir istraživanja, prikazan na slici 1 (str. 68), pokazuje da istraživanje obuhvaća mjerenje sljedećih konstrukata:

- × metakognitivnog znanja
- × metakognitivnog doživljaja zadatka i rada na zadatku
- × motivacije za rad na zadatku
- × istraživačkih (kognitivnih) vještina i strategija uključenih u 1) formuliranje istraživačkih pitanja i hipoteza, 2) eksperimentiranje i 3) zaključivanje o odnosima između varijabli
- × metakognitivnih vještina
- × stečenog znanja o odnosima između varijabli u modelu zadatka

Mjerenje ovih različitih konstrukata podrazumijeva korištenje različitih izvora i metoda prikupljanja podataka, kao i različitu dinamiku ponavljanja mjera tijekom istraživanja.

U tablici 7 popisane su korištene skupine mjera i njihov raspored unutar mjerenja.

*Tablica 7*  
Korištene mjere i njihov raspored unutar mjerenja

<b>GRUPNO ISPITIVANJE</b>	
Metakognitivno znanje (prvi upitnik)	
<b>INDIVIDUALNO ISPITIVANJE (1. DO 4. MJERENJE)</b>	
<b>Neposredno prije rada na zadatku</b>	Motivacija i emocionalno stanje Prospektivni metakognitivni doživljaj Razgovor o teorijama učenika o učincima čimbenika na uništenje šuma
<b>Za vrijeme rada na zadatku</b>	Prije svakog eksperimenta Plan/namjera (Što ćeš sad istražiti?) Hipoteze (Što očekuješ da ćeš otkriti, što misliš što će biti ishod ovog eksperimenta?)
	Nakon svakog 4. eksperimenta Metakognitivni doživljaj (procjena truda, osjećaj težine, procjena potrebnog broja eksperimenata) Motivacija (procjena samoefikasnosti i emocionalnog stanja)
	Poslije svakog eksperimenta Zaključak (Što si otkrio? Što si zaključio o učinku čimbenika na temelju provedenog eksperimenta?)
<b>Neposredno nakon rada na zadatku</b>	Motivacija Retrospektivni metakognitivni doživljaj Razgovor o teorijama učenika o učincima čimbenika na uništenje šuma
<b>Nakon četvrtog mjerenja (Završni upitnik)</b>	Metakognitivno znanje (drugi upitnik) Znanje o odnosima nezavisnih i zavisne varijable u zadatku o uništenju šuma Procjena sudjelovanja u istraživanju Procjena uspješnosti rada na zadatku i atribucijske procjene

Metakognitivno znanje je mjereno pomoću upitnika prije individualnog ispitivanja na zadatku istraživačkog učenja te poslije zadnje (četvrte) situacije rada u FILE-u.

Motivacijske mjere i mjere metakognitivnog doživljaja su također upitničke mjere, a uzimane su unutar pojedinih mjerenja neposredno prije rada, za vrijeme rada i neposredno nakon rada na zadatku.

Kognitivne i metakognitivne vještine su većim dijelom praćene računalno (putem neprestanog praćenja tragova pomoću računalnog automatskog zapisnika) tijekom rada na zadatku, ali se njihovo mjerenje temelji i na prikupljanju verbalnih protokola, koji sadrže odgovore učenika na istraživačičina pitanja, kao i «misli naglas» iskaze ispitanika.

Mjere stečenog znanja o odnosima između varijabli su, s jedne strane, utemeljene na razgovorima istraživačice i učenika o teorijama učenika o učincima pojedinih čimbenika na uništenje šuma, koji su vođeni neposredno prije i poslije učenikovog rada u FILE-u, a, s

druge strane, na bilježenju predviđenih rezultata eksperimenata u računalni automatski zapisnik.

U nastavku je detaljno opisan korišteni instrumentarij i mjere pojedinih konstrukata.

#### ***4.5.1. Metakognitivno znanje***

U istraživanju su mjerena dva elementa metakognitivnog znanja: metakognitivno znanje o cilju zadatka istraživačkog učenja i metakognitivno znanje o strategijama rada na zadatku.

Ti su elementi metakognitivnog znanja ispitani putem upitnika koji predstavlja prilagodbu postupaka korištenih kod Kuhn i Pearsall (1998) i Keselman (2003).

Upitnik je prvi puta primijenjen na grupnom sastanku, nakon što su se učenici izabrani za individualno ispitivanje upoznali s FILE programom i pokaznim zadatkom o dječaku Petru koji kasni u školu, a koji je istovjetne strukture kao zadatak o uništenju šuma. Drugi je put upitnik primijenjen individualno nakon četvrtog mjerenja, u sklopu završnog upitnika.

Upitnik se sastojao od dva dijela. Prvi dio sadrži dva pitanja otvorenog tipa koja ispituju dva elementa metakognitivnog znanja:

1. Poznavanje cilja zadatka istraživačkog učenja, i
2. Poznavanje valjanih strategija rada na zadatku istraživačkog učenja.

Drugi dio upitnika ispituje metastrateško znanje na konkretnom primjeru zadatka o dječaku Petru koji kasni u školu, a sastoji se od jednog zatvorenog i tri otvorena pitanja.

##### *Prvi dio upitnika metakognitivnog znanja*

Pitanja kojima se ispituje metakognitivno znanje učenika stavljena su u kontekst zamišljenog razgovora ispitanika i drugih učenika iz razreda. U takvoj situaciji, koja može za učenike predstavljati smisleni i realni okvir, učenik treba nekom zamišljenom prijatelju objasniti vlastite ideje o cilju i strategijama rada na zadatku. Odgovarajući na postavljena pitanja u takvoj situaciji, učeniku je olakšano eksternaliziranje vlastitih metakognitivnih znanja, čime ona postaju dostupna i istraživanju.

Konkretno, u prvom mjerenju metakognitivnog znanja koje se odvijalo tijekom grupnog sastanka na kojem je učenicima predstavljen FILE na primjeru zadatka o dječaku Petru koji kasni u školu, učenici su u prvom dijelu upitnika metakognitivnog znanja zamoljeni da zamisle sljedeću situaciju:

Zamisli sljedeću situaciju: „Prijatelju iz drugog razreda prepričavaš što smo danas radili na ovom sastanku. Ukratko opisuješ da se radi o istraživanju i da ćeš sudjelovati u njemu tako da ćeš raditi na jednom računalnom zadatku.

Nakon toga slijedi pitanje kojim se ispituje koliko učenik razumije cilj zadatka istraživačkog učenja, odnosno utvrđuje se što učenik podrazumijeva pod tim ciljem.

Pitanje o metakognitivnom znanju o cilju zadatka je strukturirano kao što slijedi:

*I. Prijatelj te zainteresirano pita: A što ti trebaš napraviti na tom zadatku? Koji je tvoj cilj na tome zadatku, što trebaš postići?*

*Što bi ti odgovorio prijatelju?*

Nakon toga, ispituje se metastrateško znanje, odnosno razumijevanje strategija potrebnih za uspješno rješavanje zadatka istraživačkog učenja. U tu je svrhu učenicima predstavljen sljedeći odlomak s pitanjem:

*II. Prijatelj je nakon tvojeg objašnjenja uglavnom shvatio što je cilj zadatka. Sad mu još nešto nije jasno, pa te pita: Znači, program je takav da u svakom retku odabereš jednu sličicu, klikneš na nju, i onda poslije pogledaš pravi rezultat. Kako odrediš koje ćeš sličice birati za pojedini eksperiment (redak u programu), da bi uspješno riješio zadatak?*

*Što bi ti odgovorio prijatelju?*

Druga primjena upitnika metakognitivnog znanja bila je uklopljeno u primjenu završnog upitnika, nakon četvrtog mjerenja. Situacija koju su učenici trebali zamisliti odgovarajući na pitanja o metakognitivnom znanju o cilju i strategijama rada na zadatku bila je ponešto drugačija nego u prvoj primjeni, ali suštinski istovjetna:

*Kroz ovo ste istraživanje stekli neke istraživačke vještine i ponešto naučili o tome kako provoditi eksperimente. Vjerojatno biste sad mogli prenijeti svoje znanje drugim učenicima u razredu.*

*Prisjetite se, molim vas, računalnog zadatka o uništavanju šuma na kojem ste radili i zamislite da ste sada u situaciji u kojoj trebate učenicima iz razreda pokazati taj zadatak i podučiti ih tome kako ga uspješno rješavati.*

*Molim te odgovori na sljedeća dva pitanja imajući na umu da su tvoji odgovori namijenjeni drugim učenicima koji nisu sudjelovali u istraživanju.*

Pitanja koja slijede jednaka su onima u prvom mjerenju, osim što su postavljena u trećem licu jednine (zbog drugačije uvodne situacije):

*I. Što učenik treba napraviti na tom zadatku? Koji je njegov cilj na tome zadatku, što treba postići?*

*II. Kako učenik treba odrediti koje će sličice birati za pojedini eksperiment (redak u programu), da bi uspješno riješio zadatak?*

### *Drugi dio upitnika metakognitivnog znanja*

U ovom dijelu upitnika metakognitivno znanje se ispituje na primjeru zadatka o dječaku Petru koji kasni u školu. Učenici su trebali vrednovati strategije rada koje za rješavanje zadatka koriste dvoje izmišljenih učenika imenovanih Matija i Nika, koji zajedno rade na tome zadatku. Nakon provedenog prvog eksperimenta, Matija i Nika se razilaze u mišljenjima o tome kako provesti drugi eksperiment i biraju različite kombinacije čimbenika za istraživanje njihovog utjecaja na Petrovo kašnjenje. Prijedlog jednog učenika<sup>27</sup> predstavlja valjanu strategiju eksperimentiranja (strategiju kontrole varijable), a prijedlog drugog učenika predstavlja nevaljanu strategiju, tzv. strategiju «drži jednu varijablu konstantnom u jednom trenutku». Učenici su trebali odrediti koji prijedlog drugog eksperimenta smatraju boljim (Matijin ili Nikin) te obrazložiti svoj odgovor (u formi odgovora na otvoreno pitanje).

U nastavku je prikazan taj zadatak, kako je korišten u prvoj primjeni upitnika:

---

<sup>27</sup> U prvoj primjeni upitnika metakognitivnog znanja valjanu strategiju eksperimentiranja predlaže Nika, a u drugom mjerenju Matija. U obje primjene prvi eksperiment je bio identičan, a prijedlozi Nike i Matije su se u prvom i drugom mjerenju razlikovali.

Zamisli sad drugu situaciju:

Dvoje prijatelja iz razreda, Matija i Nika, rade zajedno na zadatku koji ste upravo vidjeli. Žele otkriti što ima, a što nema utjecaj na to koliko Petar kasni u školu. Tek su počeli i dogovorili su se da prvi redak ('eksperiment') bude ovakav:

					→	Dobiveni rezultat bio je: Petar je zakasnio u školu <b>15</b> minuta.
vozi gradski bicikl	jede sendvič kod kuće	vozi se u društvu druge djece	nosi samo nužne bilježnice u torbi	nosi tenisice		

Matija i Nika sad trebaju napraviti drugi redak ('eksperiment') u programu. Među njima je došlo do neslaganja o tome kako nastaviti.

Matija i Nika imaju različite ideje o tome kako bi trebalo napraviti drugi redak.

Pažljivo promotri Matijin i Nikin prijedlog toga kako napraviti drugi eksperiment.

Matijin prijedlog					
	vozi trkaći bicikl	jede sendvič kod kuće	vozi se sam i to što brže može	nosi sve što mu može zatrebati	nosi cipele

Nikin prijedlog					
	vozi gradski bicikl	jede sendvič putem kad se vozi	vozi se u društvu druge djece	nosi samo nužne bilježnice u torbi	nosi tenisice

Također, učenici su trebali odgovoriti na otvorena pitanja o tome što bi se moglo saznati o utjecaju prikazanih čimbenika na Petrovo kašnjenje u slučaju da su Matija i Nika odlučili prihvatiti prijedlog provedbe drugog eksperimenta koji je dao Matija, odnosno koji je dala Nika.

Ovim se zadacima ispituje razumijevanje učenika o vrijednosti strategije kontrole varijable za zaključivanje o utjecaju pojedinog čimbenika na rezultat, ali se posredno ispituje i učenikovo razumijevanje cilja zadatka kao onog u kojem se ispituje učinak pojedinih čimbenika.

### Kodiranje odgovora učenika u upitniku metakognitivnog znanja

Pri kodiranju odgovora učenika na dva otvorena pitanja u prvom dijelu upitnika metakognitivnog znanja koja ispituju učenikovo razumijevanje cilja zadatka istraživačkog učenja i razumijevanje strategija potrebnih za uspješno rješavanje zadatka, korištena je kodna shema razina metakognitivnog znanja koju su razvile Kuhn i Pearsall (1998). Metakognitivno znanje o cilju zadatka i metastrateško znanje su kodirani zasebno, ali su pojedine razine unutar dvaju podvrsta metakognitivnog znanja konceptualno izjednačene.

U tablici 8 je prikazana korištena kodna shema, a u nastavku su pobliže objašnjene pojedine razine.

**Tablica 8**  
Razine metakognitivnog znanja o cilju zadatka i metastrateškog znanja. Prilagođeno na temelju Kuhn i Pearsall (1998)

Razina	Metakognitivno znanje o cilju zadatka		Metastrateško znanje	
	Opis razine	Tipičan odgovor učenika	Opis razine	Tipičan odgovor učenika
0	Bez uvida u cilj zadatka - opis postupka rješavanja zadatka	<i>Treba odabrati sličice i kliknuti na rezultat</i>	Bez znanja o strategijama – bez svjesnosti o potrebi strategije	<i>Izaberi što god želiš, Klikneš na sličice</i>
1	Postizanje pozitivnog ishoda	<i>Pomoći Petru da ne kasni</i>	Odabir sličica koje doprinose pozitivnom ishodu	<i>Izabereš kombinaciju sličica koje pomažu Petru da ne kasni, izabereš najbrže elemente</i>
2	Analiza na razini slučaja	<i>Ispitati koliko će Petar kasniti u različitim slučajevima</i>	Odabir različitih kombinacija (slučajeva) i opažanje rezultata	<i>Probati različite kombinacije, da bi se vidjelo kakav je rezultat</i>
3	Analiza na razini čimbenika, ali bez njihovog izdvajanja (razlikovanja)	<i>Saznati što utječe na to koliko Petar kasni</i>	-	-
4	Analiza na razini čimbenika koja uključuje više čimbenika	<i>Saznati ima li utjecaja gdje Petar doručkuje, kako ide u školu, koju obuću nosi.....</i>	Usporedba slučajeva u kojima se razlikuje više čimbenika	<i>Usporediti koliko Petar kasni ako ide trkačim ili gradskim biciklom, jede doručak kod kuće ili putem.....</i>
5	Analiza na razini čimbenika, uz usmjerenost na pojedini čimbenik	<i>Saznati kakav utjecaj ima svaki pojedini čimbenik</i>	Usporedba slučajeva u kojima je samo jedan čimbenik promijenjen	<i>Usporediti kad Petar ide trkačim i kad ide gradskim biciklom</i>
6	-	-	Usporedba slučajeva u kojima je samo jedan čimbenik promijenjen, a ostali su nepromijenjeni	<i>Mijenjaš samo jedan po jedan čimbenik, da bi vidio utječe li taj čimbenik na rezultat</i>

Učenici koji se po metakognitivnom znanju nalaze na razini 0 ne pokazuju postojanje bilo kakvog uvida u zahtjeve zadatka. Upitani o cilju zadatka istraživačkog učenja, ti učenici uobičajeno opisuju postupak rada na njemu, a slične odgovore daju i na pitanje o tome kako treba rješavati zadatak, odnosno birati čimbenike („sličice“) za eksperimente.

Učenici koji postižu razinu 1 nadilaze razumijevanje zadatka kao neposredno izvršavanje potrebnih radnji („klikanje na sličice“), i pomiču se prema razumijevanju cilja i strategija rada koje je tipično za tzv. inženjerski pristup, a koje karakterizira usmjerenost na ishod (rezultat) eksperimenata. Naime, na toj razini ciljem zadatka smatra se postizanje pozitivnog ishoda (dobivanje rezultata koji označava minimalno kašnjenje u zadatku o dječaku Petru koji kasni u školu ili najmanjeg stupnja uništenja šuma u zadatku o uništenju šuma), a ispravnom strategijom rada na zadatku drži se biranje čimbenika koji po očekivanjima učenika doprinose pozitivnom ishodu.

Nakon razine 1 dolazi do daljnjeg jačanja razumijevanja cilja zadatka i strategija rada na njemu, pa se već učenici koji postižu razinu 2 okreću od usmjerenosti na ishode (rezultate) eksperimenata prema analizi procesa ili čimbenika koji vode do pojedinih ishoda. Na razini 2 učenici žele ispitati npr. koliko će Petar kasniti u različitim kombinacijama čimbenika, a ispravnom strategijom rada na zadatku smatraju odabir različitih kombinacija čimbenika i opažanje rezultata koje ti slučajevi donose. Daljnji napredak unutar metakognitivnog znanja o cilja zadatka predstavlja razumijevanje zadatka kao onog kojim se želi utvrditi što utječe na ishode eksperimenata (razina 3). No, dok se na razini 3 ne uočava potreba ispitivanja pojedinih čimbenika, na razini 4 analiza se usmjerava na utvrđivanje utjecaja tih čimbenika, a na strateškom planu se sugerira usporedba eksperimenata koje se međusobno razlikuju po izabranim čimbenicima. Razina 5 u metakognitivnom znanju o cilju zadatka, odnosno razina 5 i 6 u metastrateškom znanju uključuju ključne elemente valjanog eksperimentiranja – usmjeravanje na ispitivanje svakog pojedinog čimbenika i kontroliranje utjecaja svih ostalih čimbenika, usporedbom slučajeva između kojih je samo jedan čimbenik promijenjen.

Kodiranje odgovora na otvorena pitanja u drugom dijelu upitnika metakognitivnog znanja bilo je provedeno eksplorativno (induktivno), tako da je kodna shema u potpunosti razvijena na temelju prikupljenih odgovora učenika. Manji dio odgovora učenika je iskorišten kao osnova za razvoj kodne sheme koja je obuhvatila cijeli raspon opaženih odgovora. Nakon što je napravljena ta osnovna shema, provjerena je na drugom dijelu odgovora učenika, kako bi se osiguralo da kodna shema zahvaća sve odgovore ispitanika.

Za odgovore na pitanja kojim se objašnjava izbor Nikinog ili Matijinog prijedloga kao boljeg korištena je sljedeća kodna shema:



0 – Bez objašnjenja
1 – Bez analize, potpuna usmjerenost na teorije učenika (Petar ne bi trebao niti žuriti u školu)
2 – Prevlast teorija učenika nad nalazima <i>Učenik preferira prijedlog koji ima povoljniju kombinaciju čimbenika po teorijama učenika</i> <i>Učenik ne preferira niti jedan prijedlog jer oba donose po teorijama učenika sličan rezultat</i> <i>Učenik ne preferira niti jedan prijedlog jer neka druga kombinacija čimbenika daje povoljniji rezultat po teorijama učenika</i>
3 – Razumijevanje važnosti korištenja strategije kontrole varijabli

Za odgovore na pitanja o tome što su učenici mogli saznati ako slijede prijedlog Nike/Matije korištena je sljedeća kodna shema:

1 – Točan odgovor <i>Utječe li čimbenik X na rezultat (kad je korištena kontrola varijabli)</i> <i>Ništa ne bi mogli zaključiti (kad nije korištena kontrola varijabli)</i>
0 – Netočan odgovor <i>Saznali bi koliko će Petar zakasnuti</i> <i>Saznali bi da će Petar manje/više zakasnuti</i> <i>Saznali bi da Petra neki čimbenici ubrzavaju a neki usporavaju</i> <i>Saznali bi da bi Petar brže došao da je odabrao neki drugi čimbenik/ usporava ga neki čimbenik</i>

#### 4.5.2. Metakognitivni doživljaj

*Prospektivni metakognitivni doživljaj* je ispitivan kad se učenik upoznao sa zadatkom o uništenju šuma (pročitao mu je opis zadatka i uputa za rad) i prije nego što je počeo raditi na njemu. Korištene su ljestvice procjene od pet stupnjeva.

Ispitani su sljedeći elementi metakognitivnog doživljaja:

- × Osjećaj težine zadatka: Koliko ti je zadatak težak? (uopće ne – izrazito da)
- × Procjena potrebe ulaganja truda: Koliko se trebaš potruditi da bi uspješno riješio ovaj zadatak? (uopće ne – izrazito da)
- × Procjena namjere ulaganja truda: Koliko truda namjeravaš uložiti u rješavanje zadatka? (vrlo malo – izrazito mnogo)
- × Procjena potrebnog broja eksperimenata<sup>28</sup>: Što misliš koliko ćeš eksperimenata trebati napraviti da bi riješio zadatak?
- × Procjena točnosti rješenja: Što misliš koliko točno ćeš riješiti zadatak (otkriti utjecaj čimbenika na uništenje šuma)? (potpuno netočno – u potpunosti točno)

<sup>28</sup> Ova mjera nije korištena u radu.

Za vrijeme rada na zadatku, nakon svakog četvrtog eksperimenta, učenici su davali procjenu ulaganja truda i osjećaja težine zadatka. Za mjerenje metakognitivnog doživljaja za vrijeme rada na zadatku korištene su iste ljestvice procjene, ali su pitanja bila ponešto drugačije oblikovana. Osjećaj težine je ispitivan putem pitanja «Koliko ti je teško sad raditi na zadatku?», a trud putem pitanja «Koliko truda ulažeš u rad na zadatku?» Osim toga, učenici su procjenjivali koliko još eksperimenata trebaju napraviti da bi riješili zadatak.

*Retrospektivni metakognitivni doživljaj* je ispitivan odmah nakon završetka pojedinog mjerenja, neposredno prije razgovora o teorijama učenika o odnosima varijabli.

Osim osjećaja težine (Koliko ti je zadatak bio težak?), procjene uloženog truda (Koliko si truda uložio u rješavanje zadatka?), procjene točnosti rješenja (Procijeni koliko točno si riješio zadatak), kao i procjene uspješnosti rada (Molim te procijeni kakav rezultat si ostvario na zadatku), dodane su još dvije mjere, koje su uzimane u sklopu razgovora o teorijama učenika:

- × Osjećaj uvjerenosti u cjelokupno rješenje: Koliko si uvjeren u točnost zaključaka koje si donio? (vrlo malo – izrazito mnogo)
- × Osjećaj uvjerenosti u pojedine zaključke<sup>29</sup>: Koliko si uvjeren u točnost tvoje tvrdnje o utjecaju čimbenika X na rezultat? (0% -100%)

#### **4.5.3. Motivacija i emocionalno stanje**

U istraživanju su korištene za zadatak specifične motivacijske procjene i iskazi o emocionalnim stanjima, mjereni u više točaka rada na zadatku unutar pojedinog mjerenja – prije početka, za vrijeme rada i nakon završetka (zajedno s mjerama metakognitivnog doživljaja).

Prije početka rada u FILE-u, ispitani su sljedeći elementi motivacije i emocionalnog stanja vezani uz zadatak:

- × Interes za zadatak: Koliko ti je zadatak zanimljiv? (uopće ne – izrazito da)
- × Osjećaj sviđanja: Koliko ti se općenito sviđa ovaj zadatak? (uopće ne – izrazito da)
- × Važnost ostvarivanja uspjeha na zadatku: Koliko je tebi osobno važno biti uspješan na ovom zadatku? (vrlo malo – izrazito mnogo)

---

<sup>29</sup> Ova mjera nije korištena u radu.

- × Procjena samoeфикаsnosti: Koliko se osjećaš sposobnim riješiti taj zadatak? (uopće ne – izrazito da)
- × Očekivanje uspjehа: Kakav rezultat očekuješ da ćeš postići na zadatku? (vrlo loš – izvrstan)
- × Emocionalno stanje: Kako se sad osjećaš? (bipolarne ljestvice od sedam stupnjeva: dobro - loše, napeto - opušteno, zadovoljno – nezadovoljno, umorno – odmorno, smireno – uznemireno, nesiguran u sebe – siguran u sebe)
- × Raspoloženje: Koliko si sada raspoložen-a za rješavanje zadatka? (uopće ne – izrazito da)

*Za vrijeme rada na zadatku, nakon svakog četvrtog eksperimenta, učenici su davali procjene samoeфикаsnosti i nekih emocionalnih stanja (dobro – loše, napeto – opušteno, nesiguran u sebe – siguran u sebe, motivirano (mogu još) – nemotivirano (ne mogu više)).*

Odmah *nakon završetka* pojedinog mjerenja, zajedno s ispitivanjem retrospektivnog metakognitivnog doživljaja i razgovorom o teorijama učenika o odnosima varijabli, učenici su procjenjivali svoj interes za zadatak, sviđanje zadatka, emocionalna stanja i važnost ostvarivanja uspjehа na zadatku<sup>30</sup>.

#### **4.5.4. Istraživačke (kognitivne) vještine i strategije**

##### *1. Namjera istraživanja/ planiranje pojedinog eksperimenta*

Osnovu za ovu mjeru čini pitanje koje je istraživačica postavljala učeniku prije svakog eksperimenta: *Što ćeš sad napraviti/ istražiti? Što želiš saznati u ovom eksperimentu? Kako to namjeravaš saznati?*

Za svaki provedeni eksperiment bilježi se jedna od sljedećih mogućnosti plana:

##### 1. Ispitivanje ili provjera učinka pojedinih varijabli

Primjeri ovakvog plana su: *«Sad ću vidjeti kako ispada kad stavim blizu naselja», ili «Želim vidjeti ima li razlike ako umjesto nizinskog područja stavim brežuljkasto» ili «Promijenit ću kisele kiše i nametnike pa vidjeti kako to utječe».*

---

<sup>30</sup> Nakon četvrtog mjerenja učenici su u sklopu završnog upitnika davali opću procjenu vlastite uspješnosti rješavanja zadatka, te atribucijske procjene. Te mjere nisu korištene u radu.

## 2. Ispitivanje ili provjera interakcijskog učinka

Primjeri su: «*Provjerit ću djeluju li kisele kiše drugačije na crnogoričnu šumu*» ili «*Ispitat ću smetaju li nametnici isto bjelogoričnoj šumi kao i crnogoričnoj*».

## 3. Generiranje specifičnog ishoda

«*Želim dobiti najveći/ najmanji/ srednji stupanj uništenja šuma*».

## 4 Nejasni ili neusmjereni plan

«*Želim vidjeti što će biti*» ili «*Sad ću vidjeti koliko će ovo (ova kombinacija o.a.) imati utjecaja*».

Kad je plan eksperimenta bio kodiran kao 'ispitivanje ili provjera učinka pojedinih varijabli' ili kao 'ispitivanje ili provjera interakcijskog učinka' zabilježen je i broj čimbenika koji učenik planira ispitati u tom eksperimentu, te su označeni čimbenici koje učenik namjerava ispitati.

Kad je plan eksperimenta kodiran kao 'generiranje specifičnog ishoda' ili kao 'nejasni ili neusmjereni plan', u varijabli 'broj čimbenika koje učenik planira ispitati u tom eksperimentu' zabilježen je kod koji označava 'nema namjere ispitivanja pojedinih čimbenika (ispituje se ukupna kombinacija čimbenika)'.

Na temelju kodiranja vrste istraživačke namjere (plana) na razini pojedinog eksperimenta, rezultat u ovoj mjeri na razini pojedinog mjerenja izražen je kao:

- × Postotak eksperimenata s namjerom ispitivanja jednog čimbenika
- × Postotak eksperimenata s namjerom ispitivanja pojedinih (dva ili više) čimbenika
- × Postotak eksperimenata s namjerom ispitivanja interakcijskog učinka
- × Postotak eksperimenata s namjerom generiranja specifičnog ishoda
- × Postotak eksperimenata s nejasnim planom ili planom ispitivanja učinka kombinacije

## 2. Postavljanje hipoteza

Osnovu za ovu mjeru čini pitanje koje je istraživačica postavljala prije završetka izvođenja svakog eksperimenta, u trenutku kad je učenik izabrao kategorije svih nezavisnih varijabli i odredio predviđeni rezultat eksperimenta: *Što očekuješ da ćeš otkriti, što misliš što će biti ishod ovog eksperimenta?*

Za svaki pojedini provedeni eksperiment utvrđeno je da li je učenik donio hipotezu ili ne. Hipotezama su proglašene one izjave o očekivanjima u kojima učenik predviđa kauzalni ili nekauzalni učinak određene nezavisne varijable na zavisnu varijablu. Iznimno je hipotezom priznata i implicitna tvrdnja učenika o učinku određene nezavisne varijable na zavisnu, ukoliko je postojala jasna namjera ispitivanja utjecaja samo tog čimbenika i ukoliko je iskazani predviđeni rezultat eksperimenta bio povezan s tom namjerom.

Hipotezom nisu označene izjave u kojima učenik objašnjava zašto je izabrao određeni predviđeni rezultat eksperimenta, odnosno u kojima opisuje kakav rezultat eksperimenta očekuje s obzirom na cjelokupnu kombinaciju čimbenika koju je izabrao, budući da u takvim izjavama učenik zapravo ne iskazuje vlastito očekivanje o utjecaju pojedinih čimbenika na rezultat eksperimenta.

Za svaki eksperiment u kojem je postavljena hipoteza, označeno je radi li se jednostavnoj hipotezi o učinku jedne nezavisne varijable, o jednostavnoj hipotezi o više nezavisnih varijabli, ili o složenoj hipotezi koja govori o interakciji dvaju ili više varijabli.

Unutar jednostavnih hipoteza razlikovane su inkluzivne i ekskluzivne hipoteze. Inkluzivne hipoteze su one koje iskazuju očekivanje kauzalnog učinka nezavisne varijable na zavisnu, a ekskluzivne hipoteze one koje iskazuju očekivanje nekauzalnog odnosa nezavisne i zavisne varijable.

Osim toga, za svaki eksperiment u kojem je postavljena hipoteza, određeno je za koje čimbenike je hipoteza (određene vrste) donesena<sup>31</sup>.

Na temelju kodiranja hipoteze na razini pojedinog eksperimenta, rezultat za postavljanje hipoteza na razini pojedinog mjerenja izražen je kao:

- × Postotak eksperimenata bez hipoteze
- × Postotak eksperimenata s jednostavnim hipotezama o jednoj varijabli
- × Postotak eksperimenata s jednostavnim hipotezama o više varijabli
- × Postotak eksperimenata s inkluzivnim hipotezama
- × Postotak eksperimenata s ekskluzivnim hipotezama
- × Postotak eksperimenata s interakcijskim hipotezama

---

<sup>31</sup> Ove mjere, po pojedinim čimbenicima, nisu korištene u radu.

### 3. Eksperimentiranje

Podaci za mjere vještina eksperimentiranja prikupljeni su praćenjem tragova rada na zadatku putem računalnog automatskog zapisnika.

Korištene su sljedeće mjere:

- a) Ukupan broj provedenih eksperimenata po mjerenju, te broj eksperimenata koje je učenik spontano proveo (bez poticanja istraživačice)
- b) Ukupan broj jedinstvenih eksperimenata koje je proveo ispitanik (tj. eksperimenata koji nisu ponavljani) u pojedinom mjerenju
- c) Broj ponavljanih eksperimenata u pojedinom mjerenju
- d) Postotak pokrivanja prostora eksperimenata, koji se izračunava kao broj provedenih jedinstvenih eksperimenata podijeljen s maksimalnim brojem jedinstvenih eksperimenata koji su mogući na zadatku (i.e. 48)
- e) Prosječan broj varijabli mijenjan po eksperimentu, koji broj indicira korištenje strategije kontrole varijabli (tj. strategiju «variraj samo jednu varijablu u jedno vrijeme») i sustavnost eksperimentiranja. Kad učenik koristi tu strategiju, mijenja samo jednu kategoriju varijable u pojedinom eksperimentu, u odnosu na prethodne eksperimente, čime se omogućuje donošenje valjanog zaključka o učinku te nezavisne varijable na zavisnu varijablu.
- e) Broj ostvarenih jedinstvenih ishoda. Unutar zadatka postoji pet različitih ishoda eksperimenata (stupnjeva uništenja šuma). Polazeći od činjenice da su neki eksperimenti informativniji od drugih, zato što su njihovi ishodi rjeđi, ova mjera pokazuje koliko je učenik svojim eksperimentiranjem u pojedinom mjerenju pokrio prostor eksperimenata i ostvario različite moguće ishode. Bilježeno je koliko je različitih ishoda učenik otkrio pomoću provedenih eksperimenata u pojedinom mjerenju.

### 4. Zaključivanje o odnosima između varijabli

Zaključci su odgovori na pitanja o interpretaciji nalaza o učinku čimbenika na uništenje šuma. Temelj za utvrđivanje postojanja, točnosti i valjanosti zaključaka je pitanje postavljeno nakon svakog eksperimenta: *Što si saznao/ otkrio? Što možeš zaključiti na temelju provedenog/ provedenih eksperimenata?*

Nakon provedbe svakog eksperimenta, učenik je mogao donijeti zaključak o učinku čimbenika na uništenje šuma, ili dati neki drugi odgovor, npr. ništa nisam zaključio, ne može se ništa zaključiti, ne znam.

Za svaki eksperiment je utvrđeno je li donesen zaključak o učinku čimbenika na uništenje šuma ili ne. Pritom, učenik je mogao donijeti jedan ili više zaključaka o učinku čimbenika na uništenje šuma.

Ukoliko je zaključak donesen, određeno je o kojima od pet nezavisnih varijabli je zaključak donesen.

Zatim je određeno o kojoj vrsti zaključka se radi. Postoje tri vrste zaključaka:

1. Inkluzivni zaključak
2. Ekskluzivni zaključak
3. Interakcijski zaključak

Inkluzivni zaključak je zaključak koji govori o tome da pojedina nezavisna varijabla ima učinak na rezultat u zavisnoj varijabli. Ekskluzivni zaključak je onaj koji govori da pojedina nezavisna varijabla nema učinak. Interakcijski zaključak je zaključak koji govori da učinak pojedine nezavisne varijable na zavisnu varijablu ovisi o učinku druge nezavisne varijable.

Zatim je za svaki zaključak određena i zasebno kodirana točnost i valjanost zaključka.

Točnost zaključka nije korištena kao kriterij strateške izvedbe u ovome radu, pa se detaljan prikaz kodne sheme točnosti pojedinog inkluzivnog, ekskluzivnog i interakcijskog zaključka nalazi u Prilogu u tablici 2. Ovdje je dovoljno reći da je točan zaključak onaj koji točno opisuje učinak nezavisne varijable na zavisnu varijablu, te da je, s obzirom na točnost, zaključak (u korištenom zadatku o uništenju šuma) mogao biti:

0. Netočan
1. Djelomično točan
2. Točan

Valjanost zaključaka je korištena u radu kao temeljan pokazatelj strateške izvedbe na zadatku.

S obzirom na valjanost zaključka, on je mogao biti:

## 0. Nevaljan

### 1. Valjan

Valjan zaključak je uvijek točan. Međutim, točnost nije jedini uvjet valjanosti zaključka. Da bi zaključak bio valjan, on mora biti donesen na temelju dovoljnog broja informativnih eksperimenata, odnosno na temelju usporedbe kontroliranih eksperimenata. Za jednostavne (inkluzivne i ekskluzivne) zaključke to znači da je potrebno da učenik uspoređi barem dva eksperimenta koji se međusobno razlikuju u samo jednoj razini (kategoriji) varijable čiji se učinak ispituje.

Primjer valjane usporedbe ukoliko se ispituje učinak čimbenika 'vrsta drveća u šumu':

Bjelogorična šuma - nizinski pojas - udaljeno od naselja - rijetko padaju kisele kiše - nema nametnika

Crnogorična šuma - nizinski pojas - udaljeno od naselja - rijetko padaju kisele kiše – nema nametnika

Za interakcijski zaključak, u kojem u interakciji sudjeluju dvije nezavisne varijable s dvije razine, dovoljan broj informativnih eksperimenata znači da je učenik uspoređio barem četiri eksperimenata koji se međusobno razlikuju samo u kategorijama varijabli čiji se učinak ispituje.

Primjer valjane usporedbe ukoliko se ispituje interakcijski učinak čimbenika 'vrsta drveća u šumi' i 'konfiguracija tla':

Bjelogorična šuma - nizinski pojas - udaljeno od naselja - rijetko padaju kisele kiše - nema nametnika

Crnogorična šuma - nizinski pojas - udaljeno od naselja - rijetko padaju kisele kiše – nema nametnika

Bjelogorična šuma - brežuljkasti pojas - udaljeno od naselja - rijetko padaju kisele kiše - nema nametnika

Crnogorična šuma – brežuljkasti pojas - udaljeno od naselja - rijetko padaju kisele kiše – nema nametnika

Utvrđivanje valjanost zaključka se temeljilo na analizi verbalnih protokola (odgovora na pitanje *Što si saznao?*) i pregledu računalnog automatskog zapisnika. Za svaki eksperiment u kojem je postojala izjava učenika o kauzalnom ili nekauzalnom učinku čimbenika na uništenje šuma (inkluzivni, ekskluzivni ili interakcijski zaključak), u računalnom automatskom zapisniku je utvrđeno jesu li eksperimenti provedeni do trenutka zaključivanja sadržavali nalaze koji omogućuju donošenje takvog zaključka, kao i to jesu li eksperimenti bili provedeni kao kontrolirani. Uz postojanje dokaza u podacima o kontroliranoj usporedbi eksperimenata, da bi zaključak bio proglašen valjanim, bilo je



potrebno da učenik ispravno interpretira prikupljene nalaze. Ukoliko u podacima nema nalaza, ili ukoliko učenik netočno interpretira nalaze, zaključak je proglašen nevaljanim<sup>32</sup>.

Na temelju kodiranja vrste, točnosti i valjanosti svakog pojedinog zaključka, za svakog je ispitanika u pojedinom mjerenju određen:

- × Postotak eksperimenata s inkluzivnim zaključcima
- × Postotak eksperimenata s ekskluzivnim zaključcima
- × Postotak eksperimenata s jednostavnim<sup>33</sup> zaključcima
- × Postotak eksperimenata s interakcijskim zaključcima
- × Postotak valjanih inkluzivnih/ ekskluzivnih/ jednostavnih zaključaka (u odnosu na broj donesenih zaključaka ove vrste)
- × Postotak valjanih interakcijskih zaključaka (u odnosu na broj donesenih zaključaka ove vrste)

Sve su vrijednosti za inkluzivne, ekskluzivne i jednostavne zaključke izračunate zasebno za pojedine čimbenike (nezavisne varijable) korištene u zadatku<sup>34</sup>, kao i ukupno (bez obzira na te čimbenike). Vrijednosti za interakcijske zaključke su izračunate vodeći računa o tome da jedan interakcijski zaključak uključuje dva ili više čimbenika.

#### **4.5.5. Metakognitivne vještine**

##### *1. Planiranje i organizacija rada na zadatku istraživačkog učenja u pojedinom mjerenju*

Na temelju verbalnih protokola utvrđena je struktura plana rada učenika na zadatku u pojedinom mjerenju. Struktura plana je kodirana kao dominantna (pretežna) razina postignuta za vrijeme rada na zadatku u pojedinom mjerenju. Plan može biti:

---

<sup>32</sup> Uz kodiranje valjanosti zaključaka provedeno je i kodiranje vrste nevaljanih zaključaka s obzirom na to kako su doneseni: 1. Na teoriji utemeljen zaključak; 2. Zaključak temeljen na jednom provedenom eksperimentu; 3. Zaključak temeljen na usporedbi dva ili više eksperimenata (3.1. Nekomolirana usporedba - promijenjen je ključni čimbenik čiji se učinak ispituje, ali i neki drugi čimbenici i 3.2. Nekontrastna usporedba - ključni čimbenik uopće nije variran); 4. Generalizirani zaključak i 5. Vrsta nevaljanog zaključka se ne može odrediti.

Dvostruko kodiranje vrsta nevaljanih zaključaka od strane istraživačice i suradnika je pokazalo nedovoljno slaganje među procjenjivačima. Stoga ova mjera nije korištena u kvantitativnim analizama.

<sup>33</sup> Jednostavni zaključci = inkluzivni + ekskluzivni zaključci

<sup>34</sup> Ove mjere, po pojedinim čimbenicima, nisu korištene u radu.

1. *Opći plan.* Učenici imaju plan koji odražava cjelokupnu strukturu prostora eksperimenata i koji djeluje kao opća struktura koja vodi učenike u osmišljavanju eksperimenata. Npr. učenik prvo provodi eksperimente koji uključuju bjelogoričnu šumu, a zatim eksperimente koji uključuju crnogoričnu šumu. Unutar pojedine vrste šume učenik mijenja čimbenike po redosljedu prezentacije u programu FILE.

Opći plan pomaže učenicima u pokrivanju prostora eksperimenata i vodi provođenju eksperimenata koji mogu služiti za valjanu usporedbu dvaju ili više prije provedenih eksperimenata.

2. *Djelomično organiziran plan.* Učenici planiraju više eksperimenata u slijedu, ali tijekom rada na zadatku napuštaju ili zaboravljaju plan prije njegovog potpunog dovršavanja.

3. *Lokalno ulančavanje.* Učenici izolirano uspoređuju pojedine eksperimente i nemaju uvid u širu strukturu prostora eksperimenata. Najčešće uspoređuju eksperimente koji slijede jedan za drugim, a ponekad i neke udaljene eksperimente.

4. *Bez plana.* Učenici ne izražavaju postojanje bilo kakvog plana, niti provode eksperimente nekim jasnim redosljedom. Zaključuju na temelju pojedinačnih slučajeva ili uspoređuju eksperimente bez da su unaprijed imali namjeru usporediti ih.

## 2. Organizacija podataka i praćenje rada na zadatku

Pod organizacijom podataka i praćenjem rada na zadatku podrazumijevaju se svi aktivni pokušaji praćenja i provjere eksperimenata koji govori o tome da učenik pokušava usporediti eksperimente i koordinirati prikupljene nalaze s vlastitim teorijama. Kao mjere uzimaju se podaci iz računalnog automatskog zapisnika o pomicanju gore-dolje u prozoru i vraćanju na prethodne eksperimente, i o korištenju programskih opcija 'selekcija eksperimenata' i 'organizacija eksperimenata'. Unutar svakog je mjerenja određeno koliko je puta učenik koristio pojedinu od ovih funkcija. Uz navedeno, zabilježeno je da li je učenik u pojedinom mjerenju koristio mogućnost vođenja bilježaka o provedenim eksperimentima i njihovim rezultatima.

#### 4.5.6. Stečeno znanje o kauzalnoj strukturi modela zadatka (učinak na zadatku)

Stečeno znanje o odnosima nezavisnih i zavisne varijable u modelu zadatka izraz je učinka koji učenik postiže na zadatku istraživačkog učenja. Dvije su mjere stečenog znanja korištene u ovom istraživanju, a međusobno se razlikuju po vrsti znanja koje zahvaćaju, te po tome kako i kad su podaci prikupljeni tijekom istraživanja. To su sljedeće mjere:

1. Razumijevanje odnosa nezavisnih i zavisne varijable
2. Prosječna pogreška predviđanja rezultata eksperimenata.

U nastavku su obje mjere detaljno opisane.

##### 1. Razumijevanje odnosa nezavisnih i zavisne varijable

Poznavanje odnosa između varijabli je ispitivano unutar svakog mjerenja - prije početka rada na zadatku i nakon rada, tijekom razgovora o teorijama učenika.

Izjave učenika o odnosima nezavisnih i zavisne varijable (*Utječe li čimbenik X na stupanj uništenja šuma?* i *Kakav utjecaj ima čimbenik X na rezultat?*) su uspoređene s točnim tvrdnjama o učinku pojedinih nezavisnih varijabli na zavisnu. Prikaz točnih tvrdnji nalazi se u tablici 9.

Tablica 9

Točne tvrdnje o učincima nezavisnih varijabli na uništenje šuma u zadatku istraživačkog učenja korištenom u ovome istraživanju

<b>Čimbenici koji nemaju utjecaj na uništenje šuma</b>
Konfiguracija tla <ul style="list-style-type: none"><li>▪ Šume u nizinskom pojasu su jednako uništene kao i šume u brežuljkastom pojasu.</li></ul>
Udaljenost šume od naselja <ul style="list-style-type: none"><li>▪ Šume blizu naselja su jednako uništene kao i šume daleko od naselja.</li></ul>
<b>Čimbenici koji imaju utjecaj na uništenje šuma</b>
Učestalost pojave kiselih kiša <ul style="list-style-type: none"><li>▪ Šume u kojima kisele kiše padaju rijetko manje su uništene od šuma u kojima kisele kiše padaju često ili vrlo često.</li><li>▪ Česta i vrlo česta pojava kiselih kiša međusobno se ne razlikuje u svojem učinku na uništenje šuma.</li></ul>
Pojava nametnika <ul style="list-style-type: none"><li>▪ Šume u kojima ima nametnika više su uništene od šuma u kojima nema nametnika.</li><li>▪ Djelovanje nametnika je različito s obzirom na vrstu šume – nametnici više uništavaju bjelogorične šume od crnogoričnih. To znači sljedeće: kad nema nametnika podjednako su uništene i bjelogorične i crnogorične šume. Kad ima nametnika, bjelogorične šume su podložnije uništenju.</li></ul>
Vrsta drveća u šumi <ul style="list-style-type: none"><li>▪ Bjelogorične šume su više uništene od crnogoričnih šuma, kad su prisutni nametnici.</li><li>▪ Bjelogorične šume su podjednako uništene kao i crnogorične šume, kad nisu prisutni nametnici.</li></ul>

Za svaku točnu tvrdnju o pojedinim čimbeniku učenik je mogao ostvariti maksimalno dva boda.

Za čimbenike 'konfiguracija tla' i 'udaljenost šume od naselja' učenik dobiva dva boda ukoliko izražava da pojedini od tih čimbenika nema učinak na stupanj uništenja šuma. Učenik dobiva 0 bodova ako smatra da učinak ovih čimbenika postoji, bez obzira na njegov smjer.

Za čimbenike 'vrsta drveća u šumi' i 'nametnici' učenik dobiva dva boda ukoliko navodi točan interakcijski učinak tih nezavisnih varijabli, odnosno ukoliko pri opisu učinka jednog čimbenika navodi ograničenje vezano uz kategorije drugog čimbenika. Učenik dobiva jedan bod ukoliko točno uočava samo glavni učinak pojedinog od tih čimbenika, ili ukoliko iznosi tvrdnju koja predstavlja djelomično točan interakcijski odnos sljedeće vrste *«Bjelogorične šume su uništenije od crnogoričnih šuma, ako ima nametnika i često padaju kisele kiše»*.

0 bodova se dodjeljuje za svaku netočnu tvrdnju o učinku ovih čimbenika, bez obzira odnosi li se ona na glavni učinak pogrešnog smjera ili netočan interakcijski zaključak (onaj koji povezuje druge varijable osim vrste drveća u šumi i nametnika, čak i uz točno prepoznavanje veće uništenosti bjelogoričnih šuma). Izjavama vrste *«Bjelogorične šume su uništenije od crnogoričnih šuma ako često padaju kisele kiše»* ili *«Bjelogorične šume su uništenije od crnogoričnih ako su blizu i često padaju kisele kiše»* dodjeljuje se 0 bodova.

Za čimbenik 'učestalost pojave kisele kiše' učenik dobiva dva boda ukoliko prepoznaje nelinearni učinak ove nezavisne varijable na zavisnu, a jedan bod za djelomično točni odgovor o postojanju učinka pojave kisele kiše na uništenje šuma (*«šume u kojima kisele kiše padaju češće su uništenije od šuma u kojima kisele kiše padaju rjeđe»*). Učenik dobiva 0 bodova ukoliko iznosi netočnu tvrdnju o učinku ovog čimbenika (bez obzira opisuje li tvrdnja netočan glavni učinak ili netočan interakcijski učinak ove varijable s drugim varijablama).

Bodovanje tvrdnji učenika o učinku pojedinih nezavisnih varijabli na uništenje šuma je sumirano u tablici 10.

Tablica 10

Bodovanje tvrdnji učenika o učinku nezavisnih varijabli na uništenje šuma prikupljenih tijekom razgovora o teorijama učenika prije i nakon rada na zadatku istraživačkog učenja u pojedinom mjerenju

	Djelomično točno (1 bod)	Točno (2 boda)
Vrsta šume	Bjelogorične šume – uništenije šume (bez navođenja ograničenja s obzirom na razine drugih varijabli) Bjelogorične šume – uništenije šume ako ima nametnika + još neki uvjet	Bjelogorične šume – uništenije šume, ako ima nametnika. Podjednako uništene ako nema nametnika
Konfiguracija tla	-	Nema utjecaja
Udaljenost od naselja	-	Nema utjecaja
Kisele kiše	Češće kisele kiše – uništenije šume	Kisele kiše često i vrlo često se međusobno ne razlikuju – uništenije šume
Nametnici	Ima nametnika – uništenije šume	Ima nametnika – uništenije šume, posebice kod bjelogoričnih šuma

Na temelju bodova postignutih za pojedine čimbenike, formirana je jedinstvena mjera koja predstavlja ukupan rezultat ispitanika na razgovoru o teorijama učenika. Nova mjera je zbroj bodova za pojedine čimbenike, pa raspon mogućih bodova iznosi između 0 i 10.

## 2. Pogreška predviđanja rezultata eksperimenata

Prije završavanja pojedinog eksperimenta, učenik je odabrao predviđeni rezultat eksperimenta za izabranu kombinaciju čimbenika. Odabir se provodio između pet stupnjeva uništenja šuma, a bio je moguć i odgovor ? koji je označavao nemogućnost predviđanja (a u obradi se tretirao kao nepostojeći podatak).

Iz računalnog automatskog zapisnika za svaki je eksperiment očitana veličina apsolutne razlike između predviđenog i stvarnog rezultata tog eksperimenta. Mjera pogreške se izražava kao prosječna apsolutna razlika između predviđenih i stvarnih ishoda eksperimenata unutar pojedinog mjerenja. Rezultat bliže 0 označava točnije predviđanje rezultata eksperimenata, odnosno indicira bolje razumijevanje učinaka nezavisnih varijabli.

## **4.6. Analiza podataka**

U ovom podpoglavlju ukratko su opisani postupci pripreme podataka za analizu, te navedeni postupci koji su korišteni u kvantitativnoj analizi podataka u svrhu odgovaranja na postavljena istraživačka pitanja.

Osim kvantitativne analize podataka, u istraživanju je korištena i kvalitativna analiza kojom su dubinski analizirani podaci o procesima istraživačkog učenja kod šest učenika (slučajeva). Postupci uzorkovanja učenika za studiju slučajeva i postupci kvalitativne analize su opisani u poglavljima 5.6. i 5.7. u sklopu poglavlja *Analiza procesa istraživačkog učenja tijekom rada na zadatku: kvalitativna analiza slučajeva*.

### **4.6.1. Priprema podataka za analizu**

Pregled svih korištenih mjera u prethodnom poglavlju pokazuje da je u istraživanju prikupljeno mnoštvo sirovih podataka, koji su trebali biti prilagođeni i pripremljeni za potrebe analize podataka.

Odgovori na otvorena pitanja koja su se nalazila u upitnicima i u verbalnim protokolima, temeljenima na polustrukturiranom razgovoru istraživačice i ispitanika, kao i na «misli naglas» samoiskazima, su kodirani prema kodnim shemama koje su izrađene za potrebe ovog istraživanja ili prilagođene na temelju više empirijskih istraživanja provedenih u području istraživačkog učenja (Kuhn i sur., 1992, 1995, 2000; Schauble, 1996; Kuhn i Pearsall, 1998; Keselman, 2003; Wilhelm i sur., 2005).

Postupak kodiranja odgovora u upitniku metakognitivnog znanja prikazan je u opisu tog instrumenta. Sličan postupak razvoja kodnih shema i postupka kodiranja otvorenih odgovora primijenjen je i za kodiranje istraživačkih i metakognitivnih vještina. Osnovna kodna shema se temeljila na teorijskim razmatranjima mjerenih koncepata i kodovima korištenima u prethodnim istraživanjima, ali su, na temelju pregleda odgovora prikupljenih u istraživanju, neki kodovi izmijenjeni ili izostavljeni.

Tragovi rada učenika u računalnim automatskim zapisnicima su transformirani za potrebe analize podataka prema uputama Van Rijna (1999) i Hulshofa i suradnika (2005).

Također, za potrebe analize podataka na razini pojedinog mjerenja, podaci koji su bilježeni na razini pojedinog eksperimenta su ili uprosječeni (npr. kod mjere prosječna pogreška predviđanja rezultata eksperimenata) ili izraženi kao postotak od ukupnog broja

provedenih eksperimenata (npr. postotak eksperimenata bez hipoteze). Time je omogućena analiza na razini pojedinih mjerenja, a zadržana je mogućnost analize na razini pojedinih eksperimenata.

Kako bi se utvrdila pouzdanost kodiranih mjera, provedeno je dvostruko kodiranje dijela prikupljenih podataka o istraživačkoj namjeri, postavljanju hipoteza i zaključivanju u pojedinom eksperimentu. Osim istraživačice koja je kodirala sve prikupljene podatke, kodiranje dijela podataka je nezavisno obavio njezin kolega, također psiholog i istraživač u području znanstvenog obrazovanja. Za oba je istraživača uvježbavanje postupka kodiranja provedeno na podacima dva mjerenja ispitanika koji su sudjelovali u predistraživanju. Nakon nezavisnog kodiranja tih podataka, dodijeljeni kodovi su uspoređeni, a razlike u kodiranju su raspravljene do postizanja zajedničkog stava. Uvježbavanje postupka kodiranja je tako ujedno omogućilo usuglašavanje oko spornih točaka u kodnim shemama i unaprjeđivanje kvalitete kodnih shema.

U glavnom istraživanju, iz praktičnih razloga dvostruko kodiranje nije bilo moguće obaviti za sve prikupljene podatke. Dvostruko je kodirano 20 od ukupno 134 mjerenja<sup>35</sup> (14,9%), odnosno 255 od ukupno 1639 eksperimenata (15,6%).

Proces izbora mjerenja koja su bila dvostruko kodirana je proveden na sljedeći način:

1. Slučajnim odabirom pomoću programa Research Randomizer (<http://www.randomizer.org/>) odabrano je 20 ispitanika
2. Kod tih 20 ispitanika slučajnim je odabirom određeno jedno od četiri mjerenja koje je dvostruko kodirano.

Za odgovore na otvorena pitanja u upitniku metakognitivnog znanja, provedeno je potpuno dvostruko kodiranje, odnosno kodiranje odgovora svih ispitanika.

Pouzdanost kodiranja, odnosno slaganje među procjenjivačima je izraženo putem Cohenovog Kappa koeficijenta.

Treba napomenuti da je slaganje među procjenjivačima o postavljanju hipoteze i donošenju zaključka o pojedinom čimbeniku izračunato na temelju svih provedenih eksperimenata, a ne samo na temelju eksperimenata za koje postoji slaganje među procjenjivačima da je hipoteza ili zaključak o tome čimbeniku donesen. Taj je postupak uveden kako bi se smanjila mogućnost neopravdane inflacije Kappa koeficijenta temeljem njegovog

---

<sup>35</sup> 33 ispitanika je sudjelovalo u četiri mjerenja, a jedan ispitanik u dva mjerenja. Ukupan broj mjerenja je stoga 134.

računanja na slučajevima za koje je već utvrđeno slaganje među procjenjivačima. Primjerice, od 255 eksperimenata, procjenjivači se slažu da je u 67 eksperimenata donesen zaključak o čimbeniku 'vrsta drveća u šumi'. Također se u 101 eksperimentu slažu da nije donesen zaključak o tom čimbeniku, kao i da u 73 eksperimenata nije donesen nikakav zaključak o učinku čimbenika na uništenje šuma. U 14 slučajeva dolazi do neslaganja između procjenjivača (jedan procjenjivač kaže da je zaključak o ovom čimbeniku donesen, a drugi da ili nije donesen zaključak o tome čimbeniku ili nije uopće donesen zaključak). Neopravdano je izračunavati slaganje među procjenjivačima na bazi 67 eksperimenata u kojima postoji slaganje procjenjivača o tome da je zaključak o čimbeniku 'vrsta drveća u šumi' donesen, pa je stoga pouzdanost kodiranja vrste, točnosti i valjanosti zaključka o pojedinom čimbeniku izračunata na bazi svih 255 eksperimenata.

Slaganje među procjenjivačima u mjeri vrsta nevaljanog zaključka, međutim, nije računato na temelju svih eksperimenata, već samo na temelju onih u kojima postoji slaganje procjenjivača o postojanju nevaljanog zaključka, budući se zbog malog broja slučajeva (15-tak nevaljanih zaključaka po čimbeniku) tim postupkom postiže realnija procjena pouzdanosti kodiranja.

*Tablica 11*  
Slaganje među procjenjivačima za pojedine dvostruko kodirane mjere

	Postotno slaganje (%)	Kappa
Metakognitivno znanje o cilju zadatka (prva primjena upitnika)	88,2	0,82
Metakognitivno znanje o strategijama rada na zadatku (prva primjena)	97,1	0,94
Metakognitivno znanje o cilju zadatka (druga primjena upitnika)	85,3	0,79
Metakognitivno znanje o strategijama rada na zadatku (druga primjena)	91,2	0,87
Plan eksperimenta (istraživačka namjera)	93,7	0,91
Broj čimbenika koji učenik planira ispitati u pojedinom eksperimentu	96,1	0,94
Namjera ispitivanja pojedinog čimbenika (čimbenik 1 do čimbenik 5)	96,6 do 100	0,91 do 1
Postavljena hipoteza	91,0	0,84
Postavljena hipoteza o čimbeniku (čimbenik 1 do čimbenik 5): bez hipoteze, inkluzivna, ekskluzivna, interakcijska hipoteza	91,4 do 91,8	0,85 do 0,86
Donošenje zaključka (da – ne)	97,7	0,94
Donošenje zaključka o pojedinom čimbeniku (čimbenik 1 do 5)	94,5 do 96,5	0,92 do 0,94
Vrsta zaključka o pojedinom čimbeniku (čimbenik 1 do čimbenik 5): inkluzivni, ekskluzivni, interakcijski zaključak	96,9 do 98,8	0,90 do 0,96
Točnost zaključka o pojedinom čimbeniku (čimbenik 1 do čimbenik 5): netočan, djelomično točan, točan	95,7 do 99,2	0,90 do 0,97
Valjanost zaključka o pojedinom čimbeniku (čimbenik 1 do čimbenik 5): nevaljan, valjan	96,9 do 99,2	0,90 do 0,98
Vrsta nevaljanog zaključka (čimbenik 1 do čimbenik 5) <sup>36</sup>	76,5 do 92,3	0,39 do 0,87

<sup>36</sup> Za tri čimbenika nije bilo moguće na temelju originalne kodne sheme izračunati Kappa koeficijent, zato što nije dobivena simetrična dvodimenzionalna tablica tj. oba procjenjivača nisu koristila sve moguće kodove.



Vrijednosti Kappa koeficijenta za pojedine mjere, prikazane u tablici 11 ukazuju na visoko slaganje između procjenjivača u gotovo svim mjerama. Većina mjera ima zadovoljavajuću pouzdanost kodiranja, veću od prihvatljivih 0,70 i preporučenih 0,80 (Landis i Koch, 1977). Jedinu iznimku predstavlja slaganje između procjenjivača u vrsti nevaljanog zaključka o pojedinom čimbeniku, gdje su vrijednosti za četiri čimbenika manje od 0,5. Stoga ova mjera nije uključena u kvantitativne analize podataka.

#### ***4.6.2. Kvantitativna analiza podataka***

Početna analiza podataka uključivala je određivanje deskriptivnih statističkih parametara i utvrđivanje zadovoljavanja pretpostavki za korištenje parametrijskih statističkih testova, prije svega analize varijance s ponovljenim mjerenjima. Utvrđeno je da većina ispitanih mjera, barem u nekim mjerenjima, ne udovoljava pretpostavci o normalnoj raspodjeli, a neke od korištenih mjera ne mogu se smatrati niti intervalnim ljestvicama.

Stoga se kvantitativna analiza podataka temeljila na neparametrijskim statističkim postupcima. Za odgovaranje na prvi problem i testiranje razlika između mjerenja korištena je Friedmanova ANOVA, te post hoc Wilcoxonovi testovi predznaka uz Bonferronijevu korekciju zbog višestrukih usporedbi (kriterij statističke značajnosti od  $p=,017$ ), prema uputama koje daje Field (2005). U post hoc testiranjima uspoređeni su samo susjedni parovi (prvo - drugo mjerenje, drugo - treće mjerenje i treće - četvrto mjerenje).

Iznimku od korištenja neparametrijskih statističkih postupaka predstavlja testiranje razlika u pojedinim mjerama motivacije i metakognitivnog doživljaja pomoću analize varijance s ponovljenim mjerenjima više nezavisnih varijabli. Ta je analiza korištena kako bi se uz glavne učinke faktora 'redni broj mjerenja' i faktora 'prije-poslije mjerenja', omogućilo testiranje interakcijskog učinka ovih faktora. Prije određivanja statističke značajnosti pojedinih učinaka, Mauchlyjevim testovima je provjereno zadovoljavaju li podaci pretpostavke o sfericitetu (jednakim varijancama razlika između pojedinih mjerenja). U slučaju dobivanja statistički značajnih vrijednosti Mauchlyjevog testa, odnosno utvrđivanja nejednakih varijanci razlika između pojedinih mjerenja, stupnjevi slobode kod testiranja značajnosti F-omjera učinaka faktora 'redni broj mjerenja' i interakcijskog učinka faktora

---

Stoga su kodovi 3.1.Nekontrolirana usporedba i 3.2. Nekontrastna usporedba spojeni u jedan kod 3. Zaključak temeljen na usporedbi dva ili više eksperimenata.

'rednog broja mjerenja' i 'prije-poslije mjerenja' su korigirani korištenjem Greenhouse-Geisserove procjene sfericiteta.

Za odgovaranje na drugi problem i korelacijske analize korištenih mjera korišten je Kendallov Tau koeficijent, koji je preferirani neparametrijski korelacijski koeficijent u slučajevima malih uzoraka i velikog broja vezanih rangova (Field, 2005).

Za odgovaranje na treći problem i grupiranje ispitanika u skupine korištena je hijerarhijska kluster analiza. Detaljan opis provedene analize dat je u poglavlju 5.5.2. *Profiliranje učenika s obzirom na doživljaj zadatka istraživačkog učenja*.

Za testiranje razlika između klastera i drugih grupa korišten je Kruskal-Wallisov test te post hoc Mann-Whitney testovi uz Bonferronijevu korekciju.

U prezentaciji podataka, uz rezultate testiranja statističke značajnosti razlika, prikazani su grupni podaci, prosjeci pojedinih mjera koji su izraženi na razini pojedinih mjerenja (odnosno pojedinih situacija učenja). Kao mjere centralne tendencije prikazane su i centralne vrijednosti i aritmetičke sredine. Prikaz aritmetičke sredine omogućuje usporedivost s drugim istraživanjima, koja su redovito koristila tu prosječnu vrijednost, a prikaz centralne vrijednosti opravdan je zbog nenormalnih raspodjela nekih podataka i malog broja ispitanika (unutar pojedinih skupina).

Iako se neparametrijski statistički postupci mogu koristiti na malim uzorcima, mali broj ispitanika predstavlja ograničavajući čimbenik za interpretaciju rezultata provedenih statističkih testova i za mogućnost generalizacije dobivenih nalaza, zbog male statističke snage testova, odnosno mogućnosti beta pogreške (pogreške tipa 2). Stoga se uz prikaz statističke značajnosti razlika ( $p$  vrijednost), u radu koristi i pokazatelj veličine učinka (Pearsonov koeficijent korelacije  $r$ ) izračunat prema formulama u Field (2005). Taj pokazatelj omogućuje kvantificiranje učinaka na standardiziran način i pomaže u određivanju njegove relevantnosti. Za interpretaciju veličine učinka koriste se Cohenove preporuke (1992), koje navode da se malim učinkom može smatrati onaj s  $r=,10$ , srednjim učinkom onaj s  $r=,30$ , a velikim učinkom onaj s  $r=,50$ .

## POGLAVLJE 5. REZULTATI I RASPRAVA

---

Prikaz rezultata istraživanja je strukturiran u dva osnovna dijela.

U prvom dijelu se odgovara na istraživačka pitanja na temelju analize grupnih podataka učenika kroz četiri situacije rada na istraživačkom zadatku. Dva su glavna elementa provedenih analiza:

1. Svi sudionici istraživanja čine jedinstvenu skupinu ispitanika, pa se promjene u procesima i ishodima istraživačkog učenja tijekom rada na zadatku istraživačkog učenja ispituju kao promjene u prosječnim vrijednostima koje ostvaruje skupina.
2. Analize promjena u procesima i ishodima istraživačkog učenja se temelje na razini pojedinih mjerenja (četiri situacija učenja). To znači da su za svakog učenika podaci o pojedinim eksperimentima provedenima unutar pojedinih mjerenja uprosječeni ili izraženi kao postotak od ukupnog broja provedenih eksperimenata u tom mjerenju.

Prvi dio poglavlja sastoji se od nekoliko cjelina. Prikaz rezultata započinje analizom promjena u znanju o odnosima varijabli u modelu zadatka do kojih dolazi uslijed rada na zadatku istraživačkog učenja. U nastavku su prikazane promjene u korištenju istraživačkih vještina, odnosno promjene u planiranju eksperimenata, postavljanju hipoteza, eksperimentiranju i donošenju zaključaka o učincima čimbenika na uništenje šuma. U trećem dijelu prikaza rezultata analizirane su promjene u korištenju metakognitivnih vještina i povezanost tih vještina planiranja, organiziranja i praćenja istraživačkog procesa s istraživačkim vještinama i znanjem koje učenici ostvaruju na zadatku. Četvrti dio prikaza rezultata bavi se stjecanjem metakognitivnog znanja o cilju i strategijama rada na zadatku i odnosom s istraživačkim vještinama učenika i učinkom na zadatku. Kraj prvog dijela poglavlja «Rezultati i rasprava» posvećen je analizi promjena u motivaciji i metakognitivnom doživljaju zadatka kroz četiri mjerenja, te ispitivanju uloge koju ti procesi imaju u procesima i ishodima istraživačkog učenja. U tu svrhu učenici su podijeljeni u tri različita klastera s obzirom na doživljaj zadatka, pa su analizirane razlike između klastera u pojedinim aspektima istraživačkog učenja.

Sve cjeline koje čine prvi dio prikaza rezultata popraćene su raspravom o značenju dobivenih nalaza u kontekstu ovog istraživanja i drugih istraživanja provedenih u području istraživačkog učenja, te o implikacijama koje ti nalazi imaju za teorijska razmatranja o

odnosima između kognitivnih, metakognitivnih i motivacijskih procesa istraživačkog učenja.

U drugom dijelu poglavlja «Rezultati i rasprava» pokušava se odgovoriti na istraživačka pitanja o ulozi metakognitivnih i motivacijskih procesa u istraživačkom učenju kroz kvalitativnu analizu procesa istraživačkog učenja šest slučajeva (učenika). Dubinskom analizom procesa istraživačkog učenja unutar i između pojedinih mjerenja kod učenika koji se međusobno razlikuju po motivacijskoj orijentaciji i strateškoj izvedbi na zadatku istraživačkog učenja, stječe se kvalitetniji i cjelovitiji uvid u promjene koje se događaju tijekom istraživačkog učenja i procese koji ograničavaju ili pospješuju te promjene. Kvalitativna analiza procesa istraživačkog učenja time značajno upotpunjuje odgovore na istraživačka pitanja koji su dani kroz kvantitativne analize podataka prikazane u prvom dijelu «Rezultata i rasprave».

# I. DIO: PROMJENE U PROCESIMA ISTRAŽIVAČKOG UČENJA IZMEĐU ČETIRI MJERENJA: ANALIZA SKUPNIH REZULTATA

## 5.1. Učinak na zadatku istraživačkog učenja – stjecanje znanja o odnosima između nezavisnih i zavisne varijable u modelu zadatka

Učinak učenika na zadatku istraživačkog učenja je iskazan putem dva pokazatelja stjecanja znanja o odnosima između varijabli u modelu zadatka. Jedan se pokazatelj odnosi na promjene u teorijama koje učenici imaju o učinku pojedinih čimbenika na stupanj uništenja šuma, a drugi na promjene u točnosti predviđanja rezultata eksperimenata.

U nastavku će prvo biti izloženi rezultati o promjenama u teorijama učenika. Bit će uspoređene učeničke početne i završne teorije o učinku pojedinih čimbenika na uništenje šuma, budući da one najjače svjedoče o znanju koje su učenici stekli radom na zadatku. Osim usporedbe početnih i završnih teorija učenika, bit će prikazane promjene u rezultatima na razgovorima o teorijama učenika održanima neposredno nakon svake od četiri situacije učenja, koje govore o promjenama u razumijevanju odnosa između varijabli do kojih dolazi tijekom rada na zadatku.

Na kraju, bit će izloženi rezultati o pogreškama predviđanja rezultata eksperimenata tijekom rada na zadatku.

### *5.1.1. Usporedba početnih i završnih teorija učenika o učinku čimbenika na uništenje šuma*

Usporedba početnih i završnih teorija učenika govori o znanju koje su učenici stekli radom na zadatku istraživačkog učenja i o njihovoj sposobnosti otkrivanja jednostavnih i složenih (interakcijskih, nelinearnih) odnosa među varijablama. Usporedba je posebno zanimljiva u vidu analize uspješnosti u otkrivanju pojedinih odnosa, ovisno o tome radi li se o potvrđivanju ili opovrgavanju učeničkih početnih kauzalnih i nekauzalnih teorija.

Analiza početnih teorija učenika ujedno otkriva djeluje li zadatak o uništenju šuma za ovu skupinu ispitanika u skladu s pretpostavkama o učeničkim teorijama, koje su utemeljene na spoznajama iz predispozitivnog provedenog na skupini učenika druge škole.

Tablica 12 pokazuje broj ispitanika koji ima određenu teoriju o učinku pojedinog čimbenika na uništenje šuma. Početna teorija je utvrđena neposredno prije prve situacije učenja, u trenutku kad je ispitanicima već opisan problem «Uništenje šuma» i predstavljeni pojedini čimbenici i njihove kategorije. Završna teorija je ispitana nakon zadnjeg, četvrtog mjerenja.

Tablica 12

Broj učenika s pojedinim početnim i završnim teorijama o učinku čimbenika na uništenje šuma (u zadnjem stupcu označene su potpuno točne teorije s ++, a djelomično točne teorije s +)

	Početna teorija	Završna teorija	Točan odgovor
<b>Vrsta drveća u šumi</b>			
Nema utjecaja	23	5	
Bjelogorične šume uništenije od crnogoričnih	5	12	+
Crnogorične šume uništenije od bjelogoričnih	2	0	
Bjelogorične šume uništenije od crnogoričnih, kad ima nametnika	1	15	++
Bjelogorične šume uništenije od crnogoričnih, kad ima nametnika i padaju kisele kiše	0	2	+
Bjelogorične šume uništenije od crnogoričnih, kad padaju kisele kiše	1	0	
Crnogorične šume uništenije od bjelogoričnih, kad padaju kisele kiše	1	0	
Ne zna/ nije siguran	1	0	
<b>Konfiguracija tla</b>			
Nema utjecaja	23	30	++
Šume u nizinskom pojasu uništenije od šuma u brežuljkastom pojasu	7	3	
Šume u brežuljkastom pojasu uništenije od šuma u nizinskom pojasu	2	1	
Bjelogorične šume uništenije u brežuljkastom pojasu, a crnogorične u nizinskom pojasu	1	0	
Ne zna/ nije siguran	1	0	
<b>Udaljenost šuma od naselja</b>			
Nema utjecaja	1	28	++
Šume blizu naselja uništenije od šuma daleko od naselja	32	6	
Šume daleko od naselja uništenije od šuma blizu naselja	0	0	
Ne zna/ nije siguran	1	0	
<b>Učestalost pojave kiselih kiša</b>			
Nema utjecaja	0	0	
Šume u kojima kisele kiše padaju češće uništenije od šuma u kojima kisele kiše padaju rjeđe	34	12	+
Šume u kojima kisele kiše padaju rjeđe uništenije od šuma u kojima kisele kiše padaju češće	0	0	
Šume u kojima kisele kiše padaju rijetko manje uništene od šuma u kojima kisele kiše padaju često ili vrlo često	0	22	++
<b>Pojava štetnika (nametnika)</b>			
Nema utjecaja	2	0	
Šume u kojima ima nametnika uništenije od šuma u kojima nema nametnika	27	14	+
Šume u kojima nema nametnika uništenije od šuma u kojima ima nametnika	0	0	
Šume u kojima ima nametnika uništenije od šuma u kojima nema nametnika, posebice za bjelogoričnu šumu	0	19	++
Šume u kojima ima nametnika uništenije od šuma u kojima nema nametnika, posebice za crnogoričnu šumu	1	0	
Ne zna/ nije siguran <sup>37</sup>	4	1	

<sup>37</sup> U ovoj kategoriji nalaze se odgovori: «Utjecaj nametnika ovisi o tome koje su vrste nametnici – neki su dobri, a neki loši» i «Nametnici nekad imaju, a nekad nemaju utjecaj».

### *Vrsta drveća u šumi*

Početna teorija učenika o učinku vrste drveća u šumi je za većinu učenika (23 ili 68%) nekauzalna, pa se može reći da zadatak istraživačkog učenja korišten u ovome istraživanju koji uvodi glavni (pa i interakcijski) učinak ovog čimbenika većinom predstavlja situaciju opovrgavanja učeničkih početnih nekauzalnih teorija.

Manji broj učenika (7 ili 21%) očekuje glavni učinak ovog čimbenika, ali nisu suglasni o smjeru očekivanih razlika. Za pet učenika zadatak predstavlja situaciju potvrde početne teorije, dok dvoje učenika očekuje razliku u suprotnom smjeru od one zadane zadatkom.

Zanimljivo je napomenuti da troje učenika već prije početka rada na zadatku iskazuje interakcijske teorije o učinku nezavisnih varijabli i daje elaborirana objašnjenja mogućih kauzalnih mehanizama u podlozi takvih odnosa. Dvoje ispitanika očekuje interakcijski učinak vrste šuma i pojave kiselih kiša, pa vjeruje da kisele kiše više onečišćuju jednu vrstu šuma. Jedan učenik drži da bi crnogorične šume mogle biti otpornije na nametnike od bjelogoričnih, što je upravo slučaj koji je bio zadan u zadatku.

Završne teorije učenika o učinku vrste drveća u šumi pokazuju da učenici nisu imali većih problema u otkrivanju glavnog učinka ovog čimbenika (lako su izgradili novu kauzalnu teoriju o utjecaju vrste šume), budući da tek 5 učenika (15%) ostaje na kraju istraživanja pri tvrdnji o nepostojanju razlika u stupnju uništenja bjelogoričnih i crnogoričnih šuma. Međutim, otkrivanje točnog interakcijskog odnosa ovog čimbenika i nametnika predstavlja veći problem, koji uspješno svladava samo 15 (44%) učenika. 12 učenika (35%) ne uspijeva uočiti interakcijsku vezu ovog čimbenika i nametnika, već se zadržava na teoriji o glavnom učinku vrste šume i tvrdnji o većem uništenju bjelogoričnih šuma. Dva ispitanika pretjerano generaliziraju interakcijski zaključak pa drže da su bjelogorične šume uništenije od crnogoričnih u situaciji većeg uništenja šuma (kad ima nametnika i kad padaju kisele kiše).

### *Konfiguracija tla*

Po početnoj teoriji, konfiguracija tla je za većinu ispitanika (23 ili 68%) nekauzalni čimbenik, što upućuje na to da ovaj čimbenik, kako je zadan u zadatku istraživačkog učenja, za većinu ispitanika predstavlja situaciju potvrde prethodne nekauzalne teorije.

Manji dio učenika prije rada na zadatku istraživačkog učenja očekuje glavni učinak ovog čimbenika, uglavnom u smjeru većeg uništenja šuma smještenih u nizinskom pojasu.

Usporedba početne i završne teorije o ovom čimbeniku pokazuje da učenici uglavnom nisu imali problema s potvrdom njihove početne točne nekauzalne teorije. Čak 19 učenika je imalo i početno i završno točne teorije o ovome čimbeniku, a svih 11 učenika s početno netočnim kauzalnim teorijama o učinku ovog čimbenika se pomaknulo prema završno točnoj nekauzalnoj teoriji. Ipak, četvero ispitanika (12%) koji su na početku očekivali da nema razlike u uništenju šuma ovisno o tome nalaze li se u nizinskom ili brežuljkastom pojasu, na kraju rada na zadatku istraživačkog učenja neispravno zaključuju o postojanju glavnog učinka ovog čimbenika. Ovakav nalaz ukazuje na sklonost učenika da tijekom rada na zadatku, korištenjem ograničenog i nekontroliranog skupa podataka, izgrade netočne kauzalne teorije o pojedinim čimbenicima, čak i kad nemaju prethodna kauzalna očekivanja o njima.

#### *Udaljenost šume od naselja*

Prije rada na zadatku istraživačkog učenja, učenici su bili gotovo jedinstveni u očekivanju utjecaja blizine naselja na uništenje šuma, pa se može reći da zadatak istraživačkog učenja za ovaj čimbenik predstavlja jasnu situaciju opovrgavanja prethodne kauzalne teorije. Od 33 učenika koji nemaju točnu početnu teoriju o ovom čimbeniku, velik broj (27) uspijeva nakon četiri situacije rada na zadatku shvatiti da je u tome zadatku 'udaljenost šume od naselja' nekauzalni čimbenik. Jedan ispitanik koji već u početnom mjerenju drži točnu teoriju o ovom čimbeniku, zadržava je do kraja rada na zadatku. Dakle, ukupno 28 (82%) učenika ima točnu završnu teoriju o ovome čimbeniku.

Manji broj ispitanika (6 ili 18%) niti nakon četiri situacije rada na zadatku ne uspijeva otkriti točni odnos udaljenosti šume od naselja i njenog uništenja, pa su im i početne i završne teorije o ovom čimbeniku kauzalne.

#### *Učestalost padanja kiselih kiša*

U zadatku istraživačkog učenja učestalost padanja kiselih kiša ima nelinearan učinak na uništenje šuma - vrlo često i često padanje kiselih kiša uzrokuje veće uništenje šuma od rijetkog padanja kiselih kiša, ali se gornje dvije razine međusobno ne razlikuju po svojem učinku. Učenici u svojim početnim teorijama ne razmatraju mogućnost takvog zakrivljenog odnosa, pa svi ističu da češće padanje kiselih kiša na svim razinama donosi veće uništenje šuma od rjeđeg. Završne teorije učenika pokazuju da shvaćanje nelinearnog odnosa ove nezavisne varijable i stupnja uništenja šuma predstavlja problem za znatan dio ispitanika. Naime, 12 ispitanika (35%) niti nakon četiri situacije rada na zadatku



istraživačkog učenja ne uspijeva prepoznati i integrirati informacije o postojanju razlike u uništenju šuma između razina rijetko - često i rijetko - vrlo često padanje kiselih kiša, s informacijama o nepostojanju razlike između razina često - vrlo često padanje. Ipak, većina učenika (22 ili 65%) ima točnu završnu teoriju o ovom čimbeniku.

### *Pojava nametnika*

Prema početnim teorijama učenika, pojava nametnika se smatra kauzalnim čimbenikom za uništenje šuma. 27 učenika (79%) vjeruje da su šume u kojima ima nametnika uništenije od šuma u kojima ih nema. Budući da je glavni učinak pojave nametnika u zadatku istraživačkog učenja jednak tome očekivanju učenika, može se reći da korišteni zadatak predstavlja potvrdu početne kauzalne teorije za ovaj čimbenik. To je situacija koju ispitanici lako svladavaju, te gotovo svi uočavaju postojanje glavnog učinka ovog čimbenika. Situaciju, međutim, usložnjava činjenica da se pojava nametnika nalazi u interakcijskom odnosu s vrstom drveća u šumi, što za posljedicu ima manji broj učenika s potpuno točnom završnom teorijom o ovom čimbeniku. Naime, nakon četiri situacije rada na zadatku, teoriju koja uključuje točan interakcijski učinak ovog čimbenika i vrste drveća u šumi iznosi 19 učenika<sup>38</sup> (56%), dok se 14 (41%) zadržava samo na glavnom učinku.

#### **5.1.2. Promjene teorija učenika tijekom rada na zadatku**


Osim početnih i završnih teorija učenika o učincima pojedinih čimbenika na uništenje šuma, podaci o teorijama učenika su prikupljeni nakon svake situacije rada na zadatku. Prema proceduri objašnjenj u metodološkom poglavlju, sve tvrdnje učenika o učincima pojedinih čimbenika su bodovane s obzirom na njihovu točnost. Za svaku potpuno točnu tvrdnju o učinku pojedinih čimbenika dobivena su dva boda, a za djelomično točnu<sup>39</sup> tvrdnju jedan bod. Ukupan rezultat na razgovoru o teorijama učenika nalazio se u maksimalnom mogućem rasponu od 0 do 10, a predstavlja kvantitativni pokazatelj stjecanja znanja o odnosima između varijabli u modelu zadatka.

---

<sup>38</sup> Od 19 učenika koji smatraju da nametnici više oštećuju bjelogorične šume nego crnogorične, 15 daje istovrsnu tvrdnju kad opisuju učinak vrste drveća u šumi. S druge strane, dva učenika od tih 19 navode da su bjelogorične šume uništenije od crnogoričnih kad ima nametnika i kad često padaju kisele kiše, a jedan da su bjelogorične šume «*same po sebi*» uništenije. Jedan učenik koji točno identificira interakcijski učinak kad opisuje učinak nametnika, ne uočava glavni učinak vrste šuma (već kaže «*Nema razlike u uništenju crnogorice i bjelogorice*»), što govori o tome da ne povezuje svoje različite tvrdnje o učincima pojedinih čimbenika, pa niti ne doživljuje nesukladnost između njih.

<sup>39</sup> 1 bod je dodijeljen za odgovore o čimbenicima 'vrsta drveća u šumi', 'pojava nametnika' i 'učestalost pojave kiselih kiša' kad su navedeni glavni, a ne interakcijski ili nelinearni učinci tih čimbenika.

Na slici 3 su prikazane centralne vrijednosti i raspršenja ukupnih rezultata na razgovorima o teorijama učenika, održanima poslije rada na zadatku, unutar svakog mjerenja. Detaljniji prikaz deskriptivnih statističkih pokazatelja dat je u Prilogu u tablici 3.




Slika 3. Ukupan rezultat na razgovoru o teorijama učenika poslije rada na zadatku u četiri mjerenja

Rezultati testiranja učinka 'rednog broja mjerenja' unutar ispitanika pokazuju da između četiri mjerenja postoji statistički značajna razlika u prosječnom ukupnom broju bodova na razgovorima o teorijama učenika ( $\chi^2(3)=46,56$ ,  $p<,001$ ). Pregled prosječnih vrijednosti pokazuje da prosječan ukupan broj bodova raste s  $C=5$  u prvom mjerenju do  $C=8$  u zadnjem mjerenju, ali veliki raspon rezultata koji je prisutan unutar pojedinih mjerenja ukazuje na značajne interindividualne razlike. Post hoc analiza između susjednih mjerenja pokazuje statistički značajnu razliku između prvog i drugog mjerenja ( $T_{1,2}=8,50$ ,  $z=-2,93$ ,  $p=,003$ ,  $r=,36$ ), dok razlike između drugog i trećeg ( $T_{2,3}= 9,53$ ,  $z=-2,34$ ,  $p=,019$ ,  $r=,28$ ), te trećeg i četvrtog mjerenja nisu statistički značajne uz Bonferronijevu korekciju ( $T_{3,4}=7,25$ ,  $z=-2,20$ ,  $p=,025$ ,  $r=,27$ ), iako vrijednosti  $r$  koeficijenata ukazuju na srednje velike učinke. Ovakvi rezultati upućuju na postojanje najvećeg skoka u znanju o učincima pojedinih čimbenika nakon izlaganja drugoj situaciji rada na zadatku, ali govore i o kontinuiranom

napredovanju u svladavanju kauzalne strukture modela zadatka kroz ponavljane situacije istraživačkog učenja.

Finija analiza promjena u teorijama učenika tijekom rada na zadatku razlikuje interakcijske, nekauzalne i nelinearne učinke. Na slici 4 je prikazan postotak učenika koji ostvaruje potpuno točne teorije o ovim učincima u pojedinim mjerenjima. Potvrđeno je da od prvog do četvrtog mjerenja raste broj učenika koji imaju potpuno točne teorije o interakcijskim učincima vrste drveća u šumi i nametnika ( $Q(3)=10,39, p=,016$ )<sup>40</sup>, o nekauzalnim učincima konfiguracije tla i udaljenosti šuma od naselja ( $Q(3)=24,19, p<,001$ ) i o nelinearnom učinku čimbenika 'učestalost pojave kiselih kiša' ( $Q(3)=29,00, p<,001$ ).



Slika 4. Postotak učenika koji u četiri mjerenja imaju potpuno točne teorije o interakcijskim, nekauzalnim i nelinearnim učincima zadanim u zadatku istraživačkog učenja

Slika 4 pokazuje kontinuirani rast točnosti teorija o nekauzalnim i nelinearnim učincima kroz četiri mjerenja, iako je početna razina točnosti učeničkih teorija (nakon prvog mjerenja) znatno viša za nekauzalne, nego za nelinearni učinak. Za obje vrste učinaka rast je najizrazitiji između prvog i drugog mjerenja. To posebice vrijedi za nelinearni učinak kiselih kiša, a vezano je uz činjenicu da su učenici tek u drugom mjerenju počeli u kombinacije čimbenika uvrštavati sve tri razine tog čimbenika, dok su u prvom mjerenju uglavnom birali ekstremne kategorije 'rijetko' i 'vrlo često'. Kvalitativna opažanja rada na zadatku upravo ukazuju na mogućnost da neotkivanje nelinearnog učinka kiselih kiša vjerojatno proizlazi iz nekorištenja svih razina (kategorija) ove varijable, a ne iz problema

<sup>40</sup> Podaci su dihotomizirani, pa je umjesto Friedmanove analize varijance korišten Cochranov Q test. Taj je test korišten u radu uvijek u slučaju postojanja dihotomnih ili dihotomiziranih varijabli.

netočnog „čitanja”, odnosno pogrešnog interpretiranja prikupljenih nalaza o učinku ovog čimbenika.

Napredovanje u točnosti teorija o interakcijskom učinku manje je izrazito i manje pravilno nego napredovanje u točnosti teorija o drugim vrstama učinaka. Iako je u prvom mjerenju postotak učenika s potpuno točnim teorijama o interakcijskim učincima jednak postotku učenika s potpuno točnom teorijom o nelinearnom učinku kiselih kiša, do kraja istraživanja značajno veći udio učenika prepoznaje nelinearni, nego interakcijski učinak (65% prema 44%). U trećem mjerenju čak dolazi do blagog nazadovanja u točnom prepoznavanju interakcijskog učinka vrste šume i nametnika. Opažanje rada učenika na zadatku pokazuje da taj pad kod nekih učenika prisutan zbog preokupacije ispitivanjem pojedinih glavnih učinaka u trećem mjerenju, dok je kod nekih učenika posljedica povećane mentalne usmjerenosti na mogućnost postojanja interakcijskih odnosa među čimbenicima (jer je u prethodnom mjerenju otkriveno da neki čimbenici drugačije djeluju na jednu, a drugačije na drugu vrstu šuma), zbog čega kod tih ispitanika dolazi do generalizacije interakcijskog učinka, ne samo na čimbenik 'pojava nametnika', nego i na čimbenik 'učestalost padanja kiselih kiša'. Dakako, ova je generalizacija posljedica nevaljanog ispitivanja interakcijskog učinka, i činjenice da učenici razliku u uništenju bjelogorične i crnogorične šume potvrđuju usporedbom eksperimenata u kojima su zajednički varirana oba kauzalna čimbenika (i nametnici i kisele kiše), kojima se onda i pripisuje zajednički interakcijski učinak s čimbenikom 'vrsta drveća u šumi'.

Ovi nalazi potvrđuju da je otkrivanje interakcijskih učinaka varijabli najteži zadatak koji se može postaviti pred učenike u okviru rada na zadatku istraživačkog učenja.

### ***5.1.3. Promjene u točnosti predviđanja rezultata eksperimenata tijekom rada na zadatku***

Točnost predviđanja rezultata eksperimenata je kvantitativni pokazatelj postignutog znanja o odnosima između nezavisnih i zavisne varijable u modelu zadatka. Istraživanja pokazuju da se u osnovi ovog pokazatelja nalaze drugačije istraživačke vještine u odnosu na mjere koje se temelje na otkrivanju odnosa pojedine nezavisne varijable sa zavisnom (Kuhn i Dean, 2004a; Kuhn, 2007a; Kuhn i sur., 2008, 2009). Naime, pokazuje se da pri predviđanju rezultata eksperimenata učenik treba integrirati cjelokupno znanje o odnosima nezavisnih i zavisne varijable, što je teži zadatak za ispitanike. Korelacijska analiza prosječne pogreške predviđanja rezultata eksperimenata i točnosti ispitanikovih teorija o svim čimbenicima nakon pojedinog mjerenja (tablica 13) doista i pokazuje da se radi o

zasebnim mjerama. U prva dva mjerenja povezanost između tih pokazatelja stjecanja znanja nije statistički značajna, dok je u trećem i četvrtom mjerenju prisutna (srednje) visoka korelacija – uz viši rezultat na razgovoru o teorijama učenika pojavljuje se u prosjeku manja pogreška predviđanja rezultata eksperimenata. Rezultati ove analize ukazuju na potrebu zasebnog tretiranja ovih pokazatelja stjecanja znanja u zadatku istraživačkog učenja, budući da pokazuju da se u njihovoj osnovi nalaze ponešto različiti procesi.

*Tablica 13*

Kendallova Tau korelacija prosječne pogreške predviđanja rezultata eksperimenata i točnosti teorija o svim čimbenicima nakon pojedinog mjerenja

	$\tau$
Prvo mjerenje	,14
Drugo mjerenje	-,16
Treće mjerenje	-,55***
Četvrto mjerenje	-,32*

\*  $p < ,05$  \*\*\* $p < ,001$


Deskriptivni pokazatelji o prosječnoj pogrešci predviđanja rezultata eksperimenata u pojedinim mjerenjima pokazuju da ona iznosi  $C=0,71$  u prvom mjerenju,  $C=0,45$  u drugom,  $C=0,36$  u trećem, a u četvrtom  $C=0,30$ <sup>41</sup>. Uz ove se prosječne vrijednosti vežu relativno velika raspršenja rezultata, koja govore o postojanju značajnih interindividualnih razlika u sposobnosti predviđanja rezultata eksperimenata. Te su prosječne vrijednosti, kao i rasponi rezultata prikazani na slici 5.

Budući da je već u prvom mjerenju prosječna pogreška predviđanja manja od jednog stupnja (uništenja šuma), može se utvrditi da učenici u prosjeku relativno dobro predviđaju rezultate pojedinih eksperimenata. Takav se rezultat može povezati s činjenicom da je model zadatka postavljen tako da dio nezavisnih varijabli varira s rezultatima u zavisnoj varijabli u skladu s učeničkim očekivanjima, kao i s tim da razlike u stupnju uništenja šuma između pojedinih kategorija nezavisnih varijabli nisu veće od dva stupnja.

Testiranje statističke značajnosti razlika u veličini prosječne pogreške predviđanja rezultata eksperimenata između četiri mjerenja pokazuje da se ona smanjuje od prvog do četvrtog mjerenja ( $\chi^2(3)=48,98$ ,  $p < ,001$ ). Post hoc analiza pokazuje statistički značajne razlike jedino između prvog i drugog mjerenja ( $T_{1,2}=8,20$ ,  $z=-4,28$ ,  $p < ,001$ ,  $r=,52$ ), dok između drugog i trećeg ( $T_{2,3}=15,70$ ,  $z=-1,81$ ,  $p=,07$ ,  $r=,22$ ), kao i između trećeg i četvrtog mjerenja

<sup>41</sup> Detaljniji prikaz deskriptivnih statističkih pokazatelja nalazi se u tablici 4 u Prilogu.

( $T_{3,4}=13,65$ ,  $z=-1,52$ ,  $p=,130$ ,  $r=,18$ ) one nisu opažene (a veličine učinaka ukazuje na male do srednje vrijednosti).



Slika 5. Prosječna pogreška predviđanja rezultata eksperimenata u četiri mjerenja

Može se ustvrditi da već u drugom mjerenju dolazi do značajnog pada u vrijednostima prosječne pogreške predviđanja, koja se zadržava na sličnoj razini do kraja rada na zadatku. Već u drugom mjerenju učenici značajno bolje predviđaju ishode eksperimenata koje postavljaju, pa su prosječne razlike između predviđenih i stvarnih stupnjeva uništenja šuma u prosjeku manje od pola stupnja. Kvalitativno opažanje učeničkih pristupa koje koriste pri predviđanju rezultata eksperimenata u različitim mjerenjima sugerira da učenici u prvom mjerenju predviđanja provode pogađajući stupnjeve uništenja šuma na temelju vlastitih kauzalnih teorija i često se dvoumeći između pojedinih vrijednosti, dok su u sljedećim mjerenjima ponešto sigurniji i skloniji izražavati predviđanja uz eksplicitno objašnjavanje vlastitih očekivanja o učincima (ili nepostojanje učinaka). U tim kasnijim mjerenjima, učenici se za predviđanje rezultata eksperimenata ne služe samo vlastitim očekivanjima, nego i podacima iz pamćenja o ostvarenim ishodima pojedinih eksperimenata. Pogreške u predviđanjima tad se vezuju uz pogrešnu procjenu veličine

učinaka pojedinog čimbenika ili uz nepoznavanje interakcijskih učinaka pojedinih varijabli.

#### **5.1.4. Učinak na zadatku istraživačkog učenja: integracija rezultata i rasprava**

Praćenje stjecanja znanja o odnosima između varijabli tijekom rada na zadatku i usporedba početnih i završnih učeničkih teorija na grupnoj razini pokazuje da nakon četiri situacije rada na zadatku učenici iskazuju značajno veće razumijevanje kauzalne strukture modela zadatka i većinom uspješno identificiraju učinak pojedinih čimbenika na uništenje šuma. Također je utvrđeno da sve u zadatku korištene nezavisne varijable funkcioniraju u skladu s predviđanjima temeljenima na predispozicijama, tako da za većinu ispitanika u zadatku postoje i situacije potvrde i situacije opovrgavanja početnih kauzalnih i nekauzalnih teorija.

Podaci pokazuju da učenici uglavnom nemaju velikih poteškoća niti u jednoj od tih situacija, ukoliko se radi o jednostavnim, glavnim učincima i linearnim odnosima, dok za znatan dio učenika pojava nelinearnih i, posebice, interakcijskih odnosa predstavlja zahtjev koji ne uspijevaju riješiti u ovako kratkom vremenu učenja, samostalno eksperimentirajući u multivarijantnom okruženju.

Analiza završnih teorija učenika na individualnoj razini, nadalje, ukazuje na nepotpunost stečenog znanja. Pokazuje se da samo 12 učenika (35%) nakon rada na zadatku iskazuje potpuno točne teorije o svih pet čimbenika, dok pet učenika (15%) ima točne teorije o četiri, a sedam učenika (21%) o tri čimbenika. Čak tri učenika nema potpuno točne teorije niti o jednom čimbeniku. Na temelju ovih rezultata, može se ustvrditi da, iako kroz rad na zadatku učenici postižu bolje razumijevanje kauzalne strukture modela zadatka, to je znanje na kraju istraživanja daleko od potpunog.

Druga istraživanja istraživačkog učenja, provedena na učenicima ponešto mlađe dobi (11-12 godina) i odraslima (npr. Kuhn i sur., 1995; Schauble, 1996; Wilhelm i sur., 2005), također ukazuju na probleme koje učenici imaju u razumijevanju interakcijskih odnosa između varijabli, ali i na probleme u odbacivanju početnih kauzalnih teorija u situaciji postojanja opovrgavajućih nalaza. Dok se slabo razumijevanje interakcijskih odnosa tumači slabostima u strateškim i metastrateškim vještinama potrebnima za otkrivanje složenih učinaka, ali i poteškoćama u konceptualiziranju plauzibilnih kauzalnih mehanizama koji mogu objasniti interakcijske učinke (Zohar, 1995), problemi u odbacivanju kauzalnih teorija vežu se uz veću snagu i veću (afektivnu) privrženost učenika

kauzalnim teorijama (u odnosu na nekauzalne), te uz veću mogućnost generiranja nalaza koji podržavaju netočne kauzalne nego nekauzalne teorije (Kuhn i sur., 1995). Problem odbacivanja netočnih kauzalnih teorija je, zbog veće posvećenosti učenika tim teorijama, posebice prisutan na istraživačkim zadacima čiji se sadržaj odnosi na probleme iz socijalnog područja, a manji je u zadacima koji se bave problemima iz prirodnog svijeta. Može se pretpostaviti da relativno visoka uspješnost učenika u odbacivanju vlastitih kauzalnih teorija o čimbeniku 'udaljenost šuma od naselja', koja je opažena u ovom istraživanju, proizlazi upravo iz male emocionalne vrijednosti koju kauzalna teorija o ovome čimbeniku ima za učenike. Bez obzira na to, nekoliko je učenika sve do kraja istraživanja zadržalo krive kauzalne teorije o ovome čimbeniku, a opažena je i pojava relativiziranja novostečenog znanja, ograničavanjem teorije o nepostojanju učinka blizine naselja na uništenje šuma samo na neke slučajeve (slučajeve niske uništenosti šuma).



## 5.2. Jačanje istraživačkih vještina i strategija tijekom rada na zadatku

Ovo poglavlje opisuje promjene u korištenju ključnih istraživačkih vještina i strategija do kojih dolazi tijekom rada na zadatku istraživačkog učenja. Rezultati su prikazani u slijedu koji odgovara osnovnim fazama istraživačkog procesa u Klahrovom modelu znanstvenog otkrića (Klahr, 2000). Prvo su prikazani rezultati o postavljanju istraživačkih planova i hipoteza, pa o eksperimentiranju i konačno, o donošenju zaključaka o odnosima između varijabli u modelu zadatka.

### 5.2.1. Plan istraživanja za pojedini eksperiment (istraživačka namjera)

Planiranje svrhe izvedbe svakog pojedinog eksperimenta važan je dio istraživačkog procesa, s obzirom da o postavljenom planu ovisi tijek eksperimentiranja, kao i mogućnost izvedbe valjanih istraživačkih postupaka. Što učenik namjerava ispitivati pojedinim eksperimentom izravno ovisi o njegovom metakognitivnom razumijevanju cilja zadatka i strategija potrebnih za njegovo rješavanje. Tek ako učenik razumije da je cilj zadatka analiza učinaka pojedinih čimbenika, odnosno ako razumije da je pri istraživanju potrebno usmjeriti se na jedan čimbenik u jednom trenutku, on pri planiranju pojedinog eksperimenta za cilj ima ispitivanje učinka pojedinog čimbenika. Stoga se podaci o planiranju pojedinih eksperimenata, odnosno o istraživačkoj namjeri u pojedinom eksperimentu, mogu shvatiti i kao indirektna mjera proceduralnog metakognitivnog znanja učenika, kao izraz korištenja metakognitivnih vještina planiranja i organiziranja rada na zadatku.

Svaki eksperiment koji je učenik namjeravao provesti kodiran je s obzirom na to kakav plan je učenik imao. Učenik je mogao namjeravati ispitivati učinak nekog određenog čimbenika ili ispitivati interakcijski učinak dvaju ili više čimbenika (što oboje govori o pravilnoj usmjerenosti u zadatku kojem je cilj analiza učinaka pojedinih čimbenika), ali je mogao težiti i generiranju nekog specifičnog ishoda, ili imati nekakav neusmjeren plan opažanja rezultata do kojih dovodi neka kombinacija izabranih kategorija čimbenika.

Slika 6 prikazuje postotne udjele svake od ovih vrsti planova u ukupnom broju provedenih eksperimenata (svih učenika zajedno) u četiri mjerenja<sup>42</sup>. Plan 'ispitivanje učinka pojedinih

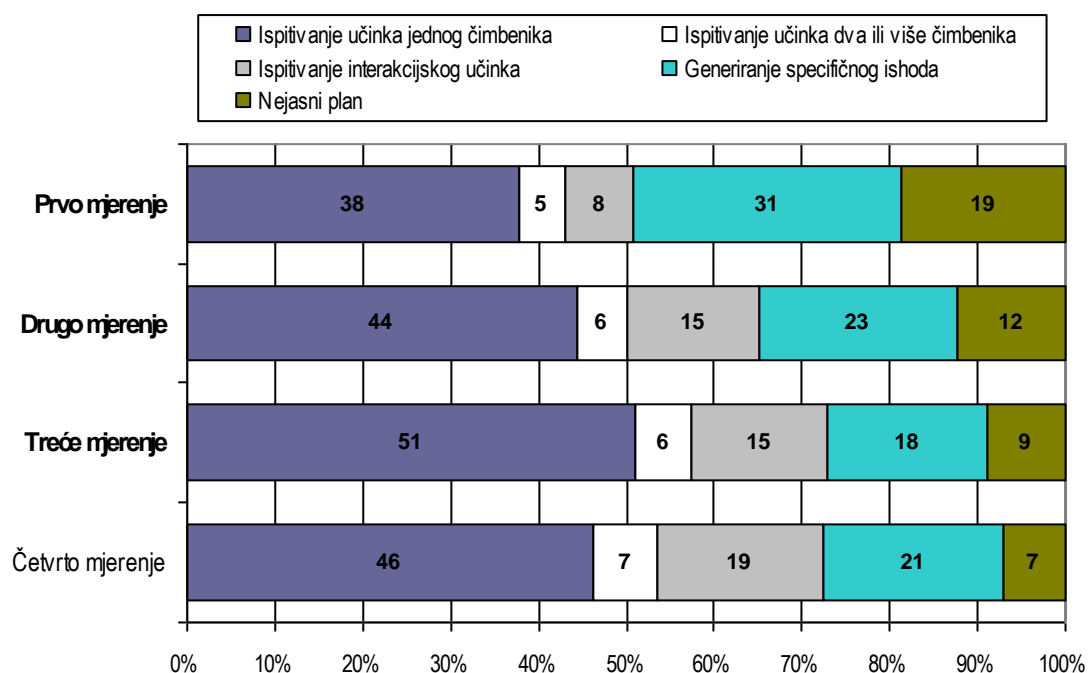
---

<sup>42</sup> U prvom mjerenju napravljeno je ukupno 400 eksperimenata, u drugom 421, u trećem 420, a u četvrtom 398. Ukupno je kroz sva četiri mjerenja napravljeno 1639 eksperimenata.

čimbenika' je podijeljen ovisno o tome je li učenik namjeravao ispitivati jednostavan učinak jednog ili više čimbenika.

U prvom mjerenju 38% od svih provedenih eksperimenata je izvedeno s namjerom ispitivanja pojedinog čimbenika, 31% eksperimenata s namjerom generiranja specifičnog ishoda, dok 19% eksperimenata ima nejasan ili neusmjeren plan. Mali udio eksperimenata u prvom mjerenju posvećen je ispitivanju interakcijskih učinaka nekih čimbenika (8%), ili istovremenom ispitivanju učinaka više od jednog čimbenika (5%).

U sljedećim mjerenjima smanjuje se postotak eksperimenata koji se provode s ciljem generiranja određenog ishoda, a pada i postotak eksperimenata s nejasnim planom. U zadnjem, četvrtom mjerenju eksperimenata s nejasnim planom je tek 7%, ali ostaje relativno veliki udio eksperimenata u kojima je cilj generirati određeni specifični ishod (21%). Kvalitativna analiza procesa rada na zadatku pokazuje da učenici u tim zadnjim mjerenjima generiraju obično najniži i najviši stupanj uništenja šume kako bi im ti eksperimenti služili kao referentne vrijednosti za usporedbu s drugim eksperimentima.



Slika 6. Postotni udjeli određene vrste planova u svim izvedenim eksperimentima u četiri mjerenja

Uz pad udjela nejasnih planova i planova generiranja određenih ishoda od prvog do četvrtog mjerenja, iz slike 6 je vidljiv rast udjela eksperimenata koji se provode s

namjerom ispitivanja interakcijskih učinaka, kao i udjela eksperimenata s planom ispitivanja učinka jednog čimbenika.

Međutim, kako su ovi postotni udjeli prikazani na slici 6 izračunati na temelju ukupnog broja eksperimenata koje su svi ispitanici zajedno proveli u pojedinom mjerenju, nedostaje informacija o individualnim obrascima i razlikama među ispitanicima u korištenju planova. Stoga je za svakog učenika u svakom pojedinom mjerenju izračunat postotak eksperimenata s pojedinom vrstom plana. Zatim su na razini cijele skupine učenika izračunate prosječne vrijednosti (centralne vrijednosti) tih postotaka. Te su prosječne vrijednosti i raspršenja prikazani u tablici 14.

Tablica 14

Centralne vrijednosti i interkvartilna raspršenja postotaka korištenja određene vrste planova u četiri mjerenja

	Ispitivanje učinka 1 čimbenika		Ispitivanje učinka više čimbenika		Ispitivanje interakcijskog učinka		Generiranje specifičnog ishoda		Nejasan plan	
	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>
Prvo mjerenje	40,10	50,00	0,00	10,00	0,00	10,00	28,65	25,23	17,90	22,98
Drugo mjerenje	47,75	29,03	0,00	10,00	0,00	25,43	17,45	29,40	9,15	20,00
Treće mjerenje	47,40	32,40	0,00	10,00	8,30	28,35	14,30	17,30	8,30	10,00
Četvrto mjerenje	50,00	32,85	0,00	15,90	15,40	33,60	18,20	26,15	0,00	10,00

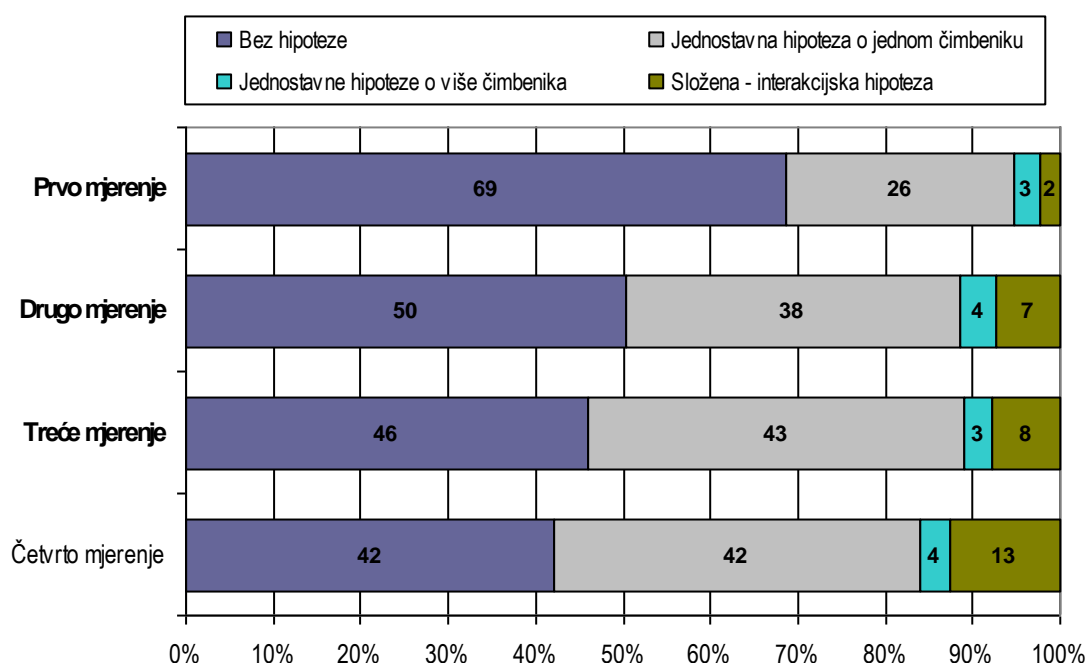
Rezultati Friedmanove analize varijance potvrđuju postojanje statistički značajnih razlika između četiri mjerenja u prosječnim vrijednostima za sve vrste planova ( $\chi^2_{\text{čimb}}(3)=10,16$ ,  $p=,017$ ;  $\chi^2_{\text{inter}}(3)=9,69$ ,  $p=,020$ ;  $\chi^2_{\text{ishod}}(3)=12,88$ ,  $p=,004$ ;  $\chi^2_{\text{nema}}(3)=19,99$ ,  $p<,001$ ), osim za ispitivanje jednostavnih učinaka dva ili više čimbenika ( $\chi^2(3)=0,90$ ,  $p=,830$ ). Post hoc testiranja razlika između susjednih mjerenja pokazuju da od prvog do drugog mjerenja pada postotak eksperimenata s nejasnim planom ( $T_{\text{nema}1,2}=11,06$ ,  $z=-2,36$ ,  $p=,017$ ,  $r=,29$ ), dok ostale razlike između susjednih mjerenja ne dosižu razinu statističke značajnosti.

Opažene promjene u vrsti planova za pojedine eksperimente tijekom rada na zadatku govore o sve boljem učeničkom razumijevanju cilja zadatka, njihovoj većoj usmjerenosti na analizu učinaka pojedinih čimbenika, i postupnom napuštanju nepromišljenog, nefokusiranog pristupa eksperimentiranju, kao i tzv. inženjerskog pristupa kojem je cilj pokazati koje kombinacije čimbenika dovode do određenih eksperimentalnih ishoda.

### 5.2.2. Postavljanje hipoteza

Analiza početnih teorija učenika o učincima pojedinih čimbenika na uništenje šuma, prikazana na početku pregleda rezultata istraživanja, pokazuje da učenici već na početku istraživanja imaju prilično jasna očekivanja o (ne)kauzalnom statusu pojedinih čimbenika. Pitanje koje se postavlja u ovome poglavlju odnosi se na to koliko učenici tijekom eksperimentiranja eksplicitno iznose ta svoja očekivanja (hipoteze) i koliko ih ta očekivanja vode u procesu eksperimentiranja.

Slika 7 prikazuje postotne udjele eksperimenata izvedenih bez hipoteze i eksperimenata izvedenih s jednostavnom i složenom hipotezom u ukupnom broju provedenih eksperimenata (svih učenika zajedno) u četiri mjerenja.



Slika 7. Postotni udjeli eksperimenata bez hipoteze i eksperimenata s jednostavnim i složenim hipotezama u svim izvedenim eksperimentima u četiri mjerenja

Za prvo mjerenje karakteristično je provođenje eksperimenata bez postavljanja hipoteze - u čak 69% provedenih eksperimenata učenici ne izražavaju očekivanja o (ne)postojanju učinka pojedinog čimbenika na uništenje šuma. Tek je u manjem dijelu eksperimenata postavljena jednostavna hipoteza o pojedinom čimbeniku (25%) ili interakcijska hipoteza (2%). Od prvog do četvrtog mjerenja u ukupnom broju provedenih eksperimenata pada udio eksperimenata bez postavljene hipoteze. Ipak, i u zadnjem mjerenju prisutan je relativno veliki postotak takvih eksperimenata (42%).

Osim provođenja analize na temelju ukupnog broja provedenih eksperimenata za sve ispitanike zajedno, postavljanje hipoteza je ispitano i na individualnoj razini. Za svakog je učenika u svakom mjerenju utvrđeno u kojem postotku eksperimenata je donesena hipoteza, i kakve je ona vrste. Prosječni postoci (centralne vrijednosti) i raspršenja na razini cijele skupine učenika su prikazani u tablici 15.

*Tablica 15*

Centralne vrijednosti i interkvartilna raspršenja postotaka eksperimenata bez/s određenom vrstom hipoteze u četiri mjerenja

	Bez hipoteze		Jednostavna hipoteza o jednom čimbeniku		Jednostavne hipoteze o više čimbenika		Interakcijska hipoteza	
	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>
Prvo mjerenje	72,50	41,14	18,47	37,98	0,00	1,47	0,00	0,00
Drugo mjerenje	50,00	40,68	39,02	34,19	0,00	7,63	0,00	11,67
Treće mjerenje	40,00	33,93	45,45	35,29	0,00	2,63	0,00	10,88
Četvrto mjerenje	40,00	39,32	41,67	25,00	0,00	3,33	10,00	22,25

Rezultati Friedmanove analize varijance potvrđuju postojanje statistički značajnih razlika između četiri mjerenja u prosječnom postotku eksperimenata bez hipoteze ( $\chi^2(3)=27,43$ ,  $p<,001$ ), eksperimenata s jednostavnim hipotezama o jednom čimbeniku ( $\chi^2(3)=14,79$ ,  $p=,002$ ) i eksperimenata s interakcijskih hipotezama ( $\chi^2(3)=18,51$ ,  $p<,001$ ), dok je udio eksperimenata s jednostavnim hipotezama o više čimbenika konstantan kroz mjerenja ( $\chi^2(3)=1,15$ ,  $p=,775$ ).

Post hoc analiza razlika između susjednih mjerenja pokazuje da se od prvog do drugog mjerenja smanjuje prosječni postotak eksperimenata bez hipoteze ( $T_{nema1,2}= 9,43$ ,  $z=-3,57$ ,  $p<,001$ ,  $r=,43$ ), iako i dalje oni čine prosječno 50% provedenih eksperimenata. Na račun tog pada, u drugom mjerenju raste postotak eksperimenata s interakcijskim hipotezama ( $T_{inter1,2}= 4,50$ ,  $z=-2,64$ ,  $p=,006$ ,  $r=,32$ ) i postotak eksperimenata s jednostavnim hipotezama o pojedinom čimbeniku ( $T_{čimb1,2}=10,95$ ,  $z=-2,30$ ,  $p=,020$ ,  $r=,28$ ).

#### *Postavljanje hipoteza određene vrste*

Postavljanje hipoteza je analizirano i s obzirom na to kakve vrste su postavljene hipoteze. Razlikovane su jednostavne inkluzivne hipoteze, jednostavne ekskluzivne hipoteze i (već navedene) interakcijske hipoteze.

### *Postavljanje inkluzivnih hipoteza*

U prvom mjerenju šest ispitanika nije postavilo niti jednu inkluzivnu hipotezu. U drugom mjerenju taj broj pada na četiri ispitanika, a u posljednja dva mjerenja zadržava se na tri učenika, iz čega se može zaključiti da je većina učenika pri radu na zadatku barem ponekad davala izjave o očekivanjima kauzalnog utjecaja određenog čimbenika na uništenje šuma. Uzimajući u obzir i te ispitanike (budući da 0% eksperimenata s inkluzivnom hipotezom predstavlja podatak koji se nalazi na donjem kraju ljestvice postotaka), u prvom mjerenju učenici u prosjeku izvode eksperimente s inkluzivnim hipotezama u 20% svih provedenih eksperimenata. Slični prosječni postoci (centralne vrijednosti) dobiveni su i za sljedeća mjerenja - u drugom mjerenju 24%, u trećem 25%, a u četvrtom 18%. Te se prosječne vrijednosti postotaka inkluzivnih hipoteza ne razlikuju statistički značajno između četiri mjerenja ( $\chi^2(3)=6,20$ ,  $p=,102$ ).

### *Postavljanje ekskluzivnih hipoteza*

Ekskluzivne hipoteze postavljaju se rjeđe od inkluzivnih. Čak 22 ispitanika nije postavilo niti jednu ekskluzivnu hipotezu u prvom mjerenju. U drugom i trećem mjerenju taj broj pada na 11 ispitanika, dok se u četvrtom mjerenju zadržava na šest ispitanika. Testiranje značajnosti promjena broja učenika koji (ne) postavljaju ekskluzivnu hipotezu provedeno je korištenjem Cochranovog testa za dihotomne zavisne podatke. Rezultati potvrđuju da se od prvog do četvrtog mjerenja povećava broj učenika koji donose ekskluzivne hipoteze ( $Q(3)=40,50$ ,  $p<,001$ ).

Ne izuzimajući podatke učenika koji nisu postavili niti jednu ekskluzivnu hipotezu u pojedinim mjerenjima, dobiveno je da je prosječan postotak (centralna vrijednost) eksperimenata u kojima je postavljena takva hipoteza u prvom mjerenju 0%, u drugom mjerenju 10%, u trećem 20% i u četvrtom 18%. Testiranje značajnosti razlika između četiri mjerenja pokazuje da prosječne vrijednosti udjela ekskluzivnih hipoteza u ukupnom broju eksperimenata rastu od prvog do četvrtog mjerenja ( $\chi^2(3)=25,59$ ,  $p<,001$ ). Statistički značajnom pokazuje se razlika između prvog i drugog mjerenja ( $T_{1,2}=12,40$ ,  $z=-2,52$ ,  $p=,010$ ,  $r=,31$ ), dok razlike između drugih susjednih mjerenja nisu statistički značajne.

### *Postavljanje interakcijskih hipoteza*

Podaci o broju učenika koji postavljaju interakcijske hipoteze sugeriraju da se one postavljaju u vrlo malom broju. U prvom mjerenju čak 28 (82%) učenika nije postavilo niti

jednu interakcijsku hipotezu. U drugom i trećem mjerenju taj broj pada na 19, a u četvrtom na 14. Testiranje statističke značajnosti razlika u broju učenika koji postavljaju interakcijsku hipotezu između četiri mjerenja potvrđuje da se od prvog do četvrtog mjerenja taj broj povećava ( $Q(3)=37,63$ ,  $p<,001$ ). U zadnjem mjerenju više od polovice ispitanika (20 učenika) postavlja interakcijske hipoteze, ali one su uglavnom malobrojne (1-2 u 10 eksperimenata).

Potrebno je, međutim, nadopuniti nalaz o porastu broja učenika koji postavljaju interakcijske hipoteze s kvalitativnim podacima o kvaliteti ili elaboriranosti tih hipoteza. Iako su kodirane kao interakcijske hipoteze, s obzirom da zahvaćaju očekivanja ispitanika o međuodnosima dvaju varijabli, opće je zapažanje da učenici ne uspijevaju dovoljno dobro opisati svoja očekivanja o interakcijskim odnosima. Uobičajeno se zadržavaju na iskazima tipa «*kod bjelogorične šume će biti isto kao i kod crnogorične*», kad zapravo žele reći da npr. čimbenik 'udaljenost šume od naselja' nema utjecaj na uništenje šuma, bez obzira radilo se o bjelogoričnim ili crnogoričnim šumama ili iskazima tipa «*nametnici više napadaju bjelogoricu*» ili «*bjelogorične šume su otpornije na nametnike*», kad žele opisati očekivani (točni) interakcijski učinak vrste šume i nametnika. Iskazane interakcijske hipoteze često su izrečene suviše šturo i ukazuju samo na jedan dio interakcijskog odnosa (npr. samo na razliku između bjelogoričnih i crnogoričnih šuma kad postoje nametnici).

### **5.2.3. Eksperimentiranje**

#### *Korištenje strategije kontrole varijabli*

Strategija kontrole varijabli, odnosno strategija «*variraj jednu varijablu u jednom trenutku*» jedina je valjana i učinkovita strategija eksperimentiranja u multivarijatnom okruženju. Učenik strategiju kontrole varijabli koristi kad eksperimente postavlja na takav način da se parovi eksperimenata međusobno razlikuju samo po jednom čimbeniku čiji utjecaj se upravo ispituje. Korištenje strategije kontrole varijabli se uobičajeno ispituje putem prosječnog broja čimbenika mijenjanih po eksperimentu. Za svakog se ispitanika odredi koliko je čimbenika mijenjao između drugog i prvog eksperimenta, između trećeg i drugog eksperimenta, između četvrtog i trećeg eksperimenta itd. pa se izračunava prosjek tih vrijednosti.

U situaciji kad bi učenik maksimalno sustavno eksperimentirao i mijenjao iz eksperimenta u eksperiment jedan po jedan čimbenik, prosječni broj čimbenika mijenjan po

eksperimentu iznosio bi 1. Nasuprot tome, kad učenik koristi nevaljane strategije eksperimentiranja i nesustavno varira više od jednog čimbenika iz eksperimenta u eksperiment, prosječni broj čimbenika mijenjan po eksperimentu iznosi između 2 i 5 (u slučaju zadatka korištenog u ovome istraživanju).

Problematičnu točku ove mjere za ispitivanje korištenja strategije kontrole varijable predstavlja činjenica da ispitanik može, realno govoreći, koristiti strategiju kontrole varijable tijekom cijelog rada na zadatku istraživačkog učenja, a da pritom ne mijenja jedan po jedan čimbenik u susjednim eksperimentima. Učenik se može, pri usporedbi parova eksperimenata, osvrnati na neki raniji, a ne na prethodni eksperiment. Npr. učenik može prvo napraviti eksperiment *bjelogorica – nizina - udaljeno od naselja - rijetko kisele kiše - nema nametnika*. U drugom eksperimentu može koristiti strategiju kontrole varijable, varirati samo jedan čimbenik (konfiguraciju tla) i napraviti sljedeću kombinaciju *bjelogorica – brežuljak - udaljeno od naselja - rijetko kisele kiše - nema nametnika*. U trećem eksperimentu može napraviti eksperiment koji se od drugog razlikuje po dva čimbenika (konfiguraciji tla i udaljenosti od naselja), ali koji ne ugrožava princip kontrole varijabli zbog usporedivosti s prvim eksperimentom, *bjelogorica – nizina - blizu od naselja - rijetko kisele kiše - nema nametnika*.


Zbog ovog ograničenja, prosječan broj čimbenika mijenjan po eksperimentu kao pokazatelj korištenja strategije kontrole varijabli ne treba tretirati u apsolutnom smislu, i sve prosječne vrijednosti veće od 1 proglašavati nevaljanim eksperimentiranjem. Mjera svoju valjanost zadržava u relativnom smislu – sustavno i valjano eksperimentiranje zasigurno rezultira manjom vrijednošću prosječnog broja čimbenika mijenjanih po eksperimentu od nesustavnog i nevaljanog eksperimentiranja.

Osim kao mjera korištenja strategije kontrole varijabli, odnosno mjera postojanja eksperimentalne kontrole, prosječan broj čimbenika mijenjan po eksperimentu se u istraživanjima tretira i kao mjera lokalne sustavnosti rada na zadatku (Schauble, 1996). Korištenje sustavnog pristupa u eksperimentiranju shvaća se izrazom metakognitivnih vještina organizacije istraživačkog procesa (Veenman i sur., 2004; Veenman i Spaans, 2005).

Za svakog je ispitanika određena prosječna vrijednost broja čimbenika mijenjanih po eksperimentu u pojedinom mjerenju, a zatim su te vrijednosti uprosječene na razini cijelog uzorka učenika.



Na slici 8 prikazane su prosječne vrijednosti prosječnog broja čimbenika mijenjanih po eksperimentu u četiri mjerenja.



Slika 8. Prosječan broj čimbenika mijenjan po eksperimentu u četiri mjerenja

Detaljniji prikaz deskriptivnih statističkih pokazatelja dat je u Prilogu u tablici 5.

U prvom mjerenju učenici prosječno mijenjaju 2,3 čimbenika po eksperimentu (uz raspon od 1,56 do 3,50). U drugom mjerenju ta vrijednost pada na 2 (uz raspon 1,53 do 3,69). U trećem i četvrtom mjerenju nastavlja se pad broja čimbenika mijenjanih po eksperimentu, pa on u prosjeku iznosi 1,9 (uz raspon od 1,44 do 3,36 u trećem, i 1,33 do 4,11 u četvrtom mjerenju). Friedmanova analiza varijance potvrđuje da između četiri mjerenja postoji statistički značajna razlika u ovoj mjeri ( $\chi^2(3)=31,53, p<,001$ ).

Post hoc testiranje razlika između susjednih mjerenja pokazuje statistički značajne razlike između prvog i drugog mjerenja ( $T_{1,2}=13,70, z=-3,52, p<,001, r=,43$ ), kao i drugog i trećeg mjerenja ( $T_{2,3}=15,88, z=-2,49, p=,012, r=,30$ ), dok se prosječan broj čimbenika mijenjan po eksperimentu između trećeg i četvrtog mjerenja ne razlikuje statistički značajno ( $T_{3,4}=15,50, z=-0,281, p=,786, r=,03$ ).

Prema smanjenju prosječnog broja čimbenika mijenjanih po eksperimentu iz mjerenja u mjerenje može se zaključiti da učenici značajno napreduju u korištenju valjanih strategija eksperimentiranja. Najveći je napredak postignut između prvog i trećeg mjerenja, kad se postiže razina koja se odražava do kraja istraživanja.

Korelacijska analiza pokazuje da je ovaj pokazatelj korištenja strategije kontrole varijabli i sustavnosti eksperimentiranja povezan s točnošću učeničkih teorija o kauzalnoj strukturi modela zadatka. Kendallovi tau koeficijenti korelacije iznose između  $\tau = -.18$  (u trećem mjerenju) i  $\tau = -.53$  (u drugom mjerenju). Učenici koji mijenjaju u prosjeku manji broj čimbenika po eksperimentu stječu više znanja o odnosima između varijabli.

#### *Pokrivanje prostora eksperimenata*

Osim korištenja strategije kontrole varijabli, važan pokazatelj kvalitete eksperimentiranja je i to koliko učenici kroz proces eksperimentiranja (učinkovito) obuhvaćaju prostor mogućih eksperimenata. Neki od pokazatelja pokrivenosti prostora eksperimenata su sljedeći:

- Ukupan broj kombinacija čimbenika koji je učenik napravio kroz eksperimentiranje
- Broj provedenih eksperimenata u pojedinim mjerenjima
- Broj jedinstvenih i ponavljanih eksperimenata u pojedinim mjerenjima
- Generirani ishodi eksperimenata u pojedinim mjerenjima

Svaki od ovih pokazatelja bit će analiziran u nastavku.

#### *Ukupan broj generiranih kombinacija čimbenika u sva četiri mjerenja*

Model zadatka postavljen u istraživanju, koji sadrži pet nezavisnih varijabli od čega četiri s dvije kategorije i jednu s tri razine, omogućuje 48 jedinstvenih kombinacija tih čimbenika. Podatak o tome koliko su učenici sveukupno, kroz sva četiri mjerenja, obuhvatili jedinstvenih kombinacija govori o tome koliko su dobro zahvatili cjelokupni prostor eksperimenata. Pritom, (pre)mali obuhvat prostora eksperimenata ukazuje na neprikladno eksperimentiranje, budući da ograničava broj informacija dostupnih učeniku, te da povećava vjerojatnost neizvođenja posebno informativnih eksperimenata (primjerice onih koji ukazuju na postojanje interakcijskih učinaka). S druge strane, potpuni obuhvat prostora eksperimenata provođenjem svih mogućih eksperimenata omogućuje potpuniji i bolji uvid u karakteristike modela zadatka i zaključivanje na temelju prosječnih vrijednosti za pojedine kategorije (izračunavanjem glavnih i interakcijskih učinaka), čak i kad nije

korištena valjana strategija eksperimentiranja, odnosno strategija kontrole varijabli. Međutim, istraživanje odnosa između nezavisnih i zavisne varijable obuhvatom cijelog prostora eksperimenata je znatno neučinkovitija metoda ispitivanja odnosa varijabli u multivarijantnom okruženju od metode usporedbe parova informativnih eksperimenata, onih koji su postavljeni na kontrolirani način. Stoga se optimalnim obuhvatom prostora eksperimenata može smatrati neka srednja vrijednost.

Učenici su u ovome istraživanju kroz četiri mjerenja u prosjeku ukupno proizveli  $C=27$  jedinstvenih kombinacija i time obuhvatili u prosjeku 55% od ukupnog broja mogućih kombinacija, što govori o relativno dobroj ukupnoj pokrivenosti prostora eksperimenata. Totalni raspon napravljenih jedinstvenih kombinacija tijekom cijelog rada na zadatku je, međutim, prilično velik i kreće se od 19 kombinacija (39% ukupnog prostora) do 37 kombinacija (76% ukupnog prostora). Najveći dio učenika (67%) smješta se u rasponu između 40 i 60% obuhvaćenog prostora eksperimenata.

#### *Broj provedenih eksperimenata u pojedinim mjerenjima*

Zadatak istraživačkog učenja korišten u ovome istraživanju je postavljen tako da učenici mogu sami odlučiti koliko će eksperimenata provesti u pojedinoj situaciji rada. Međutim, u situaciji u kojoj su učenici proveli manje od 10 eksperimenata po mjerenju i željeli završiti s radom, zamoljeni su da *«pokušaju napraviti još koji eksperiment»*. Učenicima, pritom, nije prenijeta informacija o minimalnom potrebnom broju eksperimenata.

Odluka o postavljanju minimalnog broja eksperimenata donesena je kako bi se spriječilo prerano odustajanje učenika, ali i radi usporedivosti s drugim istraživanjima koja su postavila takav zahtjev. Minimum od 10 eksperimenata je određen temeljem činjenice da taj broj predstavlja minimalan broj eksperimenata potreban za otkrivanje svih odnosa nezavisnih i zavisne varijable koji su postavljeni u zadatku.

Međutim, uvođenje potrebnog minimalnog broja eksperimenata ima i svoj jasni nedostatak koji se očituje u umjetnom ujednačavanju broja provedenih eksperimenata kod različitih ispitanika, što zapravo invalidira korištenje ove mjere, primjerice, kao pokazatelja perzistencije učenika na zadatku.

Kako bi se, ipak, zahvatila mjera spontanog broja provedenih eksperimenata, taj je podatak bilježen zasebno od ukupnog broja provedenih eksperimenata u pojedinom mjerenju.

Prikaz prosječnih vrijednosti i raspršenja ovih mjera dat je u Prilogu u tablici 6.

Učenici su u prosjeku spontano napravili između 10 i 12 eksperimenata po mjerenju ( $C=10$  u prvom, drugom i četvrtom mjerenju, a u trećem  $C=11$ ). Između četiri mjerenja ne postoji statistički značajna razlika u prosječnom spontanom broju eksperimenata ( $\chi^2(3)=0,61$ ,  $p=,892$ ).

Međutim, totalni raspon spontanog broja eksperimenata je izrazito velik i kreće se između 4 i 26 u prvom, 2 i 30 u drugom, 4 i 21 u trećem, te 5 i 20 u četvrtom mjerenju.

Znatan dio učenika (oko 1/3 u pojedinom mjerenju) je napravio manje od potrebnih 10 eksperimenata, te su od istraživača bili zamoljeni za provedbu dodatnih<sup>43</sup>. Gledajući neovisno o kojem mjerenju se radi, ukupno je čak 23 učenika (68%) barem u jednom mjerenju napravilo spontano manje od 10 eksperimenata. Uočeni su različiti obrasci takvog ponašanja. Samo dva učenika spontano rade manje od 10 eksperimenata u svim mjerenjima. Jedan dio ispitanika to radi u prvim mjerenjima, a poslije se spontano prilagođavaju zahtjevima zadatka, dok drugi dio učenika provodi premalo eksperimenata u kasnijim fazama rada – onda kad imaju dojam da su riješili zadatak, razumjeli sve odnose varijabli i «*nemaju više što za ispitati*».

U odnosu na spontani broj eksperimenata, ukupni broj eksperimenata je tek nešto veći (centralne vrijednosti u pojedinim mjerenjima se kreću između 10,5 u prvom mjerenju i 12 u trećem mjerenju), dakako, zbog provedbe dodatnih eksperimenata kod učenika s manje od 10 spontanih eksperimenata. Niti u ovoj mjeri ne postoje statistički značajne razlike od prvog do četvrtog mjerenja ( $\chi^2(3)=3,95$ ,  $p=,266$ ).

#### *Jedinstveni i ponavljani eksperimenti*

Uz bilježenje spontanog i ukupnog broja eksperimenata provedenih u pojedinom mjerenju, analizirano je koliko je u pojedinom mjerenju bilo jedinstvenih, a koliko ponavljanih eksperimenata. Dok broj ponavljanih eksperimenata govori o učeničkoj nepažljivosti pri radu<sup>44</sup>, odnosno o nedovoljnom praćenju procesa rada na zadatku<sup>45</sup>, ili o fiksaciji ispitanika

---

<sup>43</sup> Kvalitativni podaci ukazuju da su dodatni eksperimenti nekad korišteni bez svrhe novog učenja (samo da se zadovolji zahtjev istraživačice), a nekad su donijeli nove uvide o odnosima između varijabli.

<sup>44</sup> Kvalitativni podaci pokazuju da se samo jednom dogodilo da je učenik namjerno ponovio jedan eksperiment koji je već proveo u istome mjerenju, s namjerom utvrđivanja toga daje li ista kombinacija čimbenika isti rezultat u tome ponavljanju. Niti jedan drugi učenik nije smatrao potrebnim to provjeravati, iako je u «pravim» istraživanjima potrebno očekivati određeni varijabilitet eksperimentalnih rezultata za istu kombinaciju nezavisnih varijabli. Zbog potrebe korištenja jednostavnog modela odnosa između varijabli, mogućnost varijabilnog ishoda nije bila ugrađena u korišteni zadatak.

<sup>45</sup> Opažanje rada učenika na zadatku također pokazuje da je kod nekih ispitanika ponavljanje eksperimenata namjerno korišteno radi lakšeg praćenja procesa rada na zadatku. U tim je slučajevima ponavljan eksperiment koji ima ishod 1, koji je uvijek iznova služio kao «referentni pokus» u odnosu na kojeg je

na utvrđivanje samo nekih odnosa između varijabli u modelu zadatka, provođenje jedinstvenih eksperimenata odražava sposobnost učenika da pri eksperimentiranju optimalno koriste dostupne podatke. Program FILE u kojem se radi na zadatku omogućuje da učenik odjednom vidi četiri eksperimenata, ali korištenjem funkcije organiziranja i selekcije eksperimenata, kao i pomicanjem u prozoru gore-dolje, pružena je mogućnost učenicima da prate već napravljene eksperimente i ne ponavljaju iste. Dobro razvijene istraživačke vještine podrazumijevaju korištenje tih mogućnosti programa i neponavljanje istih kombinacija čimbenika unutar pojedinih mjerenja.

Prikaz prosječnih vrijednosti i raspršenja ovih mjera u pojedinim mjerenjima dat je u Prilogu u tablici 7.

Učenici u prosjeku imaju po mjerenju 10 jedinstvenih eksperimenata, dok se ponavlja između 0 i 1 eksperiment.

Testiranje statističke značajnosti učinka 'rednog broja mjerenja' pokazuje da između četiri mjerenja nije dobivena statistički značajna razlika u prosječnom broju jedinstvenih eksperimenata ( $\chi^2(3)=1,80$ ,  $p=,616$ ), kao ni u broju ponavljanih eksperimenata ( $\chi^2(3)=2,18$ ,  $p=,543$ ).

Podaci o ponavljanju eksperimenata su analizirani i frekvencijski. Broj učenika s određenim brojem ponavljanih eksperimenata u pojedinim mjerenjima je prikazan u tablici 16.

*Tablica 16*  
Broj učenika s određenim brojem ponavljanih eksperimenata u četiri mjerenja

	Prvo mjerenje	Drugo mjerenje	Treće mjerenje	Četvrto mjerenje
	<i>n</i>	<i>n</i>	<i>n</i>	<i>n</i>
Niti jedan ponovljen eksperiment	17	14	21	15
1 ponovljen eksperiment	9	9	4	12
2 ponovljena eksperimenta	4	5	3	3
Više od 2 ponovljena eksperimenta	4	6	6	4

Podaci iz tablice 16 pokazuju da oko polovice ispitanika unutar pojedinog mjerenja ne ponavlja niti jedan eksperiment, dok se kod druge polovice ispitanika ponavljanje eksperimenata pojavljuje barem jednom. Od ukupnog broja ispitanika, samo je pet (15%)

---


utvrđivan učinak pojedinih čimbenika. Nakon svake usporedbe dva pokusa, učenik bi ponovio početni referentni pokus za novu usporedbu sa sljedećim eksperimentom. U navedenom slučaju ponavljanje eksperimenata je zapravo pokazatelj metakognitivne aktivnosti praćenja.

onih koji nisu niti u jednom mjerenju ponovili neki eksperiment unutar istog mjerenja. Kod nekih se, pak, ispitanika pokazuje tendencija kontinuiranog ponavljanja eksperimenata, pa čak osam ispitanika ponavlja eksperimente u sva četiri mjerenja.

#### *Generirani ishodi eksperimenata u pojedinim mjerenjima*

Model zadatka postavljen je tako da postoji pet različitih ishoda eksperimenata, odnosno pet stupnjeva uništenja šuma. Ti se ishodi eksperimenata ne pojavljuju jednako često u ukupnom broju mogućih jedinstvenih kombinacija čimbenika. Ishod «1» koji označava najmanji stupanj uništenja šuma, kao i ishodi «4» i «5» koji označavaju dva najviša stupnja uništenja šuma pojavljuju se u po osam kombinacija čimbenika (17%). Ishod «3», koji predstavlja srednji stupanj uništenja šuma, je najčešći mogući ishod i pojavljuje se u 21 od 48 mogućih kombinacija (44%). Najinformativniji rezultat eksperimenata je ishod «2», koji se pojavljuje u samo tri kombinacije čimbenika (6%).

Na slici 9 je prikazana raspodjela pojedinih ishoda u ukupnom skupu mogućih jedinstvenih kombinacija čimbenika, kao i ostvarena raspodjela tih ishoda u skupu svih provedenih eksperimenata u pojedinom mjerenju (svih ispitanika zajedno).



Slika 9. Prosječni postotni udjeli provedenih eksperimenata s pojedinim ishodom u četiri mjerenja, i usporedba sa zadanim udjelom ishoda u ukupnom broju mogućih jedinstvenih kombinacija

Iz grafičkoj je prikaza vidljivo da su raspodjele provedenih eksperimenata s obzirom na to koji ishod oni proizvode vrlo slične u svim mjerenjima. Učenici u svim mjerenjima provode najviše eksperimenata s ishodom «1», koji predstavlja najmanje uništenje šuma, i eksperimenata s (teorijski gledano najčešćim) ishodom «3». Eksperimenti s ishodima «4» i «5» koji predstavljaju visoko uništenje šuma pojavljuju se podjednako, ali značajno rjeđe od već navedenih kategorija.

Rezultati Friedmanove analize varijance kojom su provjeravane razlike u prosječnim postotcima provedenih eksperimenata s pojedinim ishodima potvrđuju da učinak 'rednog broja mjerenja' nije statistički značajan niti za jedan ishod ( $\chi^2_1(3)=0,16$ ,  $p=,981$ ;  $\chi^2_2(3)=1,26$ ,  $p=,740$ ;  $\chi^2_3(3)=3,48$ ,  $p=,324$ ;  $\chi^2_4(3)=3,76$ ,  $p=,287$  i  $\chi^2_5(3)=6,11$ ,  $p=104$ ).

Za analizu istraživačkog procesa, zanimljiva je, međutim, usporedba udjela provedenih eksperimenata s određenim ishodom s udjelom tih eksperimenata u ukupnom broju mogućih jedinstvenih kombinacija čimbenika. Može se vidjeti da učenici znatno češće provode eksperimente s ishodom «1», budući da je od svih provedenih eksperimenata u pojedinom mjerenju 30-tak % takvih, dok je eksperimenata s ishodom «1» 17% u cijelom prostoru jedinstvenih kombinacija čimbenika. Kao što je već spomenuto, eksperimenti s ishodom «1» su često bili početni eksperimenti koje su ispitanici provodili, kao i eksperimenti koji su predstavljali referentne vrijednosti za usporedbu s drugim eksperimentima i utvrđivanje učinka pojedinih čimbenika. Učenici su takve eksperimente smatrali «nultom» točkom u odnosu na koju se najbolje «vide» učinci pojedinih nezavisnih varijabli.

Iako bi, načelno gledano, eksperimenti s ishodom «5» mogli služiti istoj svrsi kao i eksperimenti s ishodom «1», budući da predstavljaju samo drugi kraj iste ljestvice, ispitanici su te eksperimente proizvodili znatno rjeđe, baš u skladu s postotkom koji se očekuje na temelju udjela tih eksperimenata u cjelokupnom prostoru mogućih kombinacija.

S obzirom na tu «teorijsku» raspodjelu eksperimenata s određenim ishodom, također se može uočiti da su učenici rjeđe od očekivanog provodili eksperimente s ishodom «3». Taj nalaz je, dakako, logičan, razmatrajući ga iz pozicije manje informativnosti koju ti eksperimenti imaju za utvrđivanje učinka pojedinih čimbenika, od eksperimenata s ekstremnim ili eksperimenata s rijetkim ishodom.

Također je analizirano koliko su od pet mogućih ishoda ispitanici generirali u pojedinim mjerenjima. U tablici 17 je prikazan broj učenika koji su generirali sve moguće ishode u

pojedininim mjerenjima, kao i broj ispitanika koji su generirali tri ili četiri od pet mogućih ishoda.

*Tablica 17*

Broj ispitanika koji su generirali određeni broj ishoda u eksperimentima u četiri mjerenja

	Prvo mjerenje	Drugo mjerenje	Treće mjerenje	Četvrto mjerenje
	<i>n</i>	<i>n</i>	<i>n</i>	<i>n</i>
Generirana tri ishoda	1	7	7	6
Generirana četiri ishoda	18	10	9	11
Generirana pet ishoda	15	17	18	17

U prvom mjerenju većina je učenika provela eksperimente koji su rezultirali sa svih pet ili sa četiri ishoda, dok je samo jedan učenik generirao samo tri ishoda. U sljedećim mjerenjima raste broj učenika s malim brojem generiranih ishoda, iako većina učenika generira svih pet mogućih ishoda. Opažene promjene između prvog i ostalih mjerenja povezuju se s nalazom o češćem eksperimentiranju s ciljem generiranja specifičnih ishoda na početku istraživačkog učenja i preusmjeravanju na analizu učinaka pojedinih čimbenika u kasnijim fazama rada na zadatku.

#### **5.2.4. Donošenje zaključaka o učinku čimbenika na uništenje šume**

##### *Broj i vrsta zaključaka*

U zadatku istraživačkog učenja korištenom u ovom istraživanju nije se zahtijevalo donošenje zaključaka nakon svakog provedenog eksperimenta. Učenici su mogli donijeti toliko zaključaka o učinku čimbenika na uništenje šuma koliko su htjeli ili smatrali opravdanim. Dakle, nakon svakog provedenog eksperimenta učenici su mogli suzdržati se od donošenja zaključka ili donijeti jedan ili više zaključaka.

Imajući na umu da su učenici radeći na zadatku istraživačkog učenja imali mogućnost samostalnog određivanja ukupnog broja izvedenih eksperimenata, potrebno je bilo podatke o broju zaključaka između pojedinih učenika učiniti međusobno usporedivima. To je učinjeno izražavanjem broja zaključaka kao proporcije od ukupnog broja provedenih eksperimenata, odnosno korištenjem mjere broja zaključaka po eksperimentu.

Razlikovani su jednostavni (inkluzivni i ekskluzivni) i interakcijski zaključci.

Model zadatka korišten u ovome istraživanju koristi i jednostavne i interakcijske odnose među nezavisnim varijablama, pa zadatak pruža mogućnost analize donošenja različitih



vrsti zaključaka. Za svakog je ispitanika u pojedinom mjerenju određen broj jednostavnih, inkluzivnih i ekskluzivnih zaključaka, kao i broj interakcijskih zaključaka po eksperimentu.

*Broj jednostavnih zaključaka*

Tablica 18 pokazuje prosječan broj jednostavnih, inkluzivnih i ekskluzivnih zaključaka po eksperimentu u četiri mjerenja. Broj jednostavnih zaključaka za pojedinog učenika jednak je zbroju broja njegovih inkluzivnih i ekskluzivnih zaključaka. Detaljan prikaz deskriptivnih statističkih pokazatelja dat je u Prilogu u tablicama 8 i 9.

*Tablica 18*

Centralne vrijednosti i interkvartilna raspršenja broja jednostavnih, inkluzivnih i ekskluzivnih zaključaka po eksperimentu u četiri mjerenja

	Jednostavni zaključci		Inkluzivni zaključci		Ekskluzivni zaključci	
	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>	<i>C</i>	<i>IQR</i>
Prvo mjerenje	1,06	0,63	0,68	0,662	0,29	0,218
Drugo mjerenje	0,90	0,62	0,43	0,538	0,35	0,203
Treće mjerenje	0,79	0,33	0,38	0,268	0,33	0,182
Četvrto mjerenje	0,64	0,28	0,27	0,233	0,36	0,247

U prvom mjerenju prosječan broj inkluzivnih zaključaka donesen po eksperimentu je značajno veći od broja ekskluzivnih zaključaka ( $T=7,83$ ,  $z=4,51$ ,  $p<,001$ ,  $r=,55$ ). U drugom i trećem mjerenju nema statistički značajne razlike u prosječnom broju inkluzivnih i ekskluzivnih zaključaka po eksperimentu ( $T_1=11,37$ ,  $z=1,75$ ,  $p=,08$ ,  $r=,21$ ;  $T_2=13,28$ ,  $z=-0,47$ ,  $p=,642$ ,  $r=,06$ ). U četvrtom mjerenju učenici donose po eksperimentu čak više ekskluzivnih nego inkluzivnih zaključaka ( $T=13,30$ ,  $z=2,77$ ,  $p=,004$ ,  $r=,34$ ).

Testirajući učinak 'rednog broja mjerenja' u broju inkluzivnih zaključaka dobiveno je da od prvog do četvrtog mjerenja pada prosječan broj inkluzivnih zaključaka po eksperimentu ( $\chi^2(3)=51,57$ ,  $p<,001$ ). Post hoc analiza razlika između susjednih mjerenja pokazuje sve statistički značajne razlike: između prvog i drugog mjerenja ( $T_{1,2}=10,57$ ,  $z=-3,55$ ,  $p<,001$ ,  $r=,43$ ), drugog i trećeg mjerenja ( $T_{2,3}=10,81$ ,  $z=-3,00$ ,  $p=,002$ ,  $r=,36$ ), kao i između trećeg i četvrtog mjerenja ( $T_{3,4}=11,50$ ,  $z=-3,06$ ,  $p=,002$ ,  $r=,37$ ). Prosječne vrijednosti pokazuju da učenici u prvom mjerenju donose mnogo inkluzivnih zaključaka – dok relativni broj iznosi  $C=0,68$ , apsolutni broj iznosi u prosjeku čak osam zaključaka ove vrste. Međutim, opažene su velike interindividualne razlike u ovoj mjeri, pa se totalni raspon u prvom mjerenju

kreće od 0,19 do 3,3 inkluzivnih zaključaka po eksperimentu. Do četvrtog mjerenja prosječni broj inkluzivnih zaključaka po eksperimentu pada na  $C=0,27$ , a apsolutni broj na tri zaključka. I dalje je opažen veliki totalni raspon rezultata, koji se nalazi između vrijednosti 0,00 i 1,20.

Testirajući učinak 'rednog broja mjerenja' u broju ekskluzivnih zaključaka dobiveno je da između četiri mjerenja ne postoji statistički značajna razlika u broju donesenih ekskluzivnih zaključaka po eksperimentu ( $\chi^2(3)=7,35$ ,  $p=,059$ ). Uz prosječne vrijednosti u svakom mjerenju vežu se velika raspršenja, tako da razlika maksimalnog i minimalnog rezultata u pojedinim mjerenjima iznosi od 0,70 do 0,90.

#### *Broj interakcijskih zaključaka*

Osim broja jednostavnih zaključaka, utvrđen je i broj interakcijskih zaključaka po eksperimentu. Prosječne vrijednosti te mjere prikazane su u tablici 19.

*Tablica 19*

Centralne vrijednosti i interkvartilna raspršenja broja interakcijskih zaključaka po eksperimentu u četiri mjerenja

	<i>C</i>	<i>IQR</i>
Prvo mjerenje	0,07	0,182
Drugo mjerenje	0,03	0,209
Treće mjerenje	0,10	0,270
Četvrto mjerenje	0,17	0,204

Od prvog do četvrtog mjerenja nije utvrđena statistički značajna razlika u prosječnom broju interakcijskih zaključaka po eksperimentu ( $\chi^2(3)=7,58$ ,  $p=,054$ ).

#### *Valjanost zaključaka*

Valjanost zaključivanja o učincima pojedinih nezavisnih varijabli predstavlja ključni pokazatelj kvalitete istraživačkih vještina učenika i pokazatelj strateške izvedbe na zadatku istraživačkog učenja te krajnju točku koja se želi ostvariti u području razvoja znanstvenog razmišljanja.

Donošenje valjanih zaključaka u zadatku istraživačkog učenja odražava sposobnost učenika da zaključuju na temelju nalaza koje su stvorili provedbom eksperimenata na kontroliran način. Valjan je zaključak uvijek točan zaključak o (ne)kauzalnom statusu određene nezavisne varijable, a nužno se temelji na uporabi strategije kontrole varijabli,

odnosno na usporedbi kontroliranih eksperimenata koji se međusobno razlikuju samo po razinama (kategorijama) varijable, čiji učinak se upravo ispituje. Pri procjeni valjanosti zaključivanja, uz korištenje strategije kontrole varijabli, bilo je potrebno da učenik ispravno interpretira prikupljene nalaze i objašnjenje svog točnog zaključka temelji na provedenim eksperimentima.

U nastavku su prikazani rezultati o valjanosti jednostavnih i interakcijskih zaključaka kroz četiri situacije rada na zadatku.

### *Valjanost jednostavnih zaključaka*

Analiza valjanosti jednostavnih zaključaka započinje prikazom broja i postotka valjanih i nevaljanih zaključaka ove vrste u skupu svih donesenih jednostavnih zaključaka (svih učenika zajedno). U tablici 20 prikazani su podaci o valjanim jednostavnim, inkluzivnim i ekskluzivnim zaključcima po pojedinim mjerenjima, kao i ukupno (za sva četiri mjerenja zajedno).

*Tablica 20*

Ukupan broj jednostavnih, inkluzivnih i ekskluzivnih zaključaka, te broj i postotak valjanih i nevaljanih zaključaka donesenih u četiri mjerenja te tijekom cjelokupnog rada na zadatku istraživačkog učenja

		Valjano	Nevaljano	Ukupno
Prvo mjerenje	Inkluzivni zaključci	70 (21,0%)	264 (79,0%)	334
	Ekskluzivni zaključci	82 (67,8%)	39 (32,2%)	121
	Ukupno	152 (33,4%)	303 (66,6%)	455
Drugo mjerenje	Inkluzivni zaključci	92 (36,1%)	163 (63,9%)	255
	Ekskluzivni zaključci	102 (68,0%)	48 (32,0%)	150
	Ukupno	194 (47,9%)	211 (52,1%)	405
Treće mjerenje	Inkluzivni zaključci	88 (53,3%)	77 (46,7%)	165
	Ekskluzivni zaključci	118 (75,2%)	39 (24,8%)	157
	Ukupno	206 (64,0%)	116 (36,0%)	322
Četvrto mjerenje	Inkluzivni zaključci	66 (59,5%)	45 (40,5%)	111
	Ekskluzivni zaključci	116 (67,1%)	57 (32,9%)	173
	Ukupno	182 (64,1%)	102 (35,9%)	284
Sva četiri mjerenja zajedno	Inkluzivni zaključci	316 (36,5%)	549 (63,5%)	865
	Ekskluzivni zaključci	418 (69,6%)	183 (30,4%)	601
	Ukupno	734 (50,1%)	732 (49,9%)	1466

Učenici su u sva četiri mjerenja ukupno donijeli 865 inkluzivna zaključka, od kojih je 36,5% bilo valjano. Ekskluzivnih zaključaka je u istom razdoblju doneseno znatno manje (601), ali su oni mnogo češće proglašeni valjanima (69,6%). Najveća razlika u valjanosti između inkluzivnih i ekskluzivnih zaključaka prisutna je u prvom mjerenju, kad je ostvareno tek 21,0% valjanih inkluzivnih i čak 67,8% valjanih ekskluzivnih zaključaka. Pritom, inkluzivnih je zaključaka bilo gotovo trostruko više od ekskluzivnih. Tijekom drugog mjerenja zadržava se velika prednost valjanog zaključivanja kad je riječ o ekskluzivnim zaključcima, kao i prevlast ukupnog broja inkluzivnih zaključaka. Tijekom trećeg susreta učenika sa zadatkom istraživačkog učenja, ujednačava se broj inkluzivnih i ekskluzivnih zaključaka, ali je valjanost ekskluzivnih zaključaka i dalje značajno viša od valjanosti inkluzivnih zaključaka (75,2% prema 53,3%). U zadnjem mjerenju dolazi do prevlasti broja ekskluzivnih zaključaka pred brojem inkluzivnih zaključaka, te do ujednačavanja valjanosti dviju vrsta jednostavnih zaključaka, iako je valjanost ekskluzivnih zaključaka još uvijek viša od valjanosti inkluzivnih zaključaka (67,1% prema 59,5%).

Navedeni podaci o broju i postotnim udjelima valjanih zaključaka određene vrste u ukupnom broju donesenih zaključaka jasno govore o potrebi zasebnog razmatranja pojavnosti donošenja (valjanih) inkluzivnih i ekskluzivnih zaključaka i sugeriraju neopravdanost korištenja jedinstvene mjere valjanosti jednostavnih zaključaka. Iako i inkluzivni i ekskluzivni zaključci predstavljaju izjave o učinku, odnosno o nepostojanju učinka, jedne nezavisne varijable na zavisnu varijablu, pokazatelji broja i valjanosti ovih zaključaka kroz različita mjerenja ukazuju na njihovu nesimetričnost i različitu zahtjevnost koju predstavljaju za ispitanike.

Bez obzira na navedeni nedostatak, pokazatelj valjanosti jednostavnih zaključaka je standardni pokazatelj koji se koristi u svim istraživanjima istraživačkog učenja kao mjera koja ujedinjuje podatke o valjanosti inkluzivnih i ekskluzivnih zaključaka i koja pokazuje postignuće učenika na zadacima istraživačkog učenja. U ovome istraživanju, valjanost jednostavnih zaključaka se također koristi, uglavnom kao kriterijska mjera za izbor učenika za kvalitativnu studiju slučajeva ili za analizu povezanosti s metakognitivnim znanjima i vještinama. Korištenje ove mjere dijelom je vezano uz činjenicu da pojedini učenici u nekim mjerenjima nisu donijeli niti jedan ekskluzivan zaključak (jedan učenik u jednom mjerenju nije donio inkluzivan zaključak), dok je podatak o jednostavnim zaključcima prisutan za sve ispitanike. U Prilogu u tablici 10 prikazani su podaci o prosječnim

vrijednostima i raspršenjima mjere valjanosti jednostavnih zaključaka, a tablica 11 u Prilogu prikazuje frekvencijsku analizu pojave valjanih jednostavnih zaključaka kroz četiri mjerenja. Dakako, zbog dominantnosti inkluzivnih zaključaka u skupu jednostavnih zaključaka, podaci o valjanosti jednostavnih zaključaka i promjenama u valjanosti zaključivanja kroz četiri mjerenja slijede trend koji pokazuju inkluzivni zaključci. Ovdje je još potrebno istaknuti da podaci o valjanosti jednostavnih zaključaka pokazuju da svi učenici ostvaruju barem poneki valjani jednostavni zaključak, te da samo tri ispitanika imaju manje od 50% valjanih zaključaka ove vrste u svim mjerenjima. Za ostale je ispitanike karakteristično postojanje i valjanih i nevaljanih zaključaka u pojedinim mjerenjima, dok obrasci promjena u valjanosti zaključivanja kroz mjerenja pokazuju različite individualne putove napredovanja prema valjanom zaključivanju ili više-manje stabilnog održavanja određene razine valjanosti (tablica 12 u Prilogu).

U nastavku su prikazani podaci o valjanosti inkluzivnih i ekskluzivnih zaključaka kroz četiri mjerenja. Za svakog je ispitanika u pojedinom mjerenju određen postotak valjanih zaključaka (od ukupnog broja donesenih zaključaka određene vrste). Detaljniji prikaz deskriptivnih statističkih pokazatelja dat je u Prilogu u tablici 13.

#### *Valjanost inkluzivnih zaključaka*


U prvom mjerenju učenici u prosjeku ostvaruju 29% valjanih inkluzivnih zaključaka, u drugom mjerenju 43%, a u trećem i četvrtom 67%<sup>46</sup>. Prosječni postoci valjanih inkluzivnih zaključaka i pripadajuća raspršenja u četiri mjerenja prikazani su na slici 10.

Testiranje statističke značajnosti opaženih razlika pokazuje da od prvog do četvrtog mjerenja dolazi do rasta prosječnog postotka valjanih inkluzivnih zaključaka ( $\chi^2(3)=27,08$ ,  $p<,001$ ). Post hoc analiza razlika između susjednih mjerenja potvrđuje postojanje statistički značajne razlike između prvog i drugog mjerenja ( $T_{1,2}=14,33$ ,  $z=-2,84$ ,  $p=,003$ ,  $r=,34$ ), dok razlika između drugog i trećeg mjerenja nije statistički značajna, iako veličina učinka sugerira da se radi o srednje velikom učinku ( $T_{2,3}=10,35$ ,  $z=-2,06$ ,  $p=,039$ ,  $r=,25$ ). Razlika između trećeg i četvrtog mjerenja također nije statistički značajna ( $T_{3,4}=10,32$ ,  $z=-0,16$ ,  $p=,883$ ,  $r=,02$ ).

---

<sup>46</sup> U četvrtom mjerenju jedan ispitanik nije donio niti jedan inkluzivni zaključak, pa se izračun prosječnog postotka temelji na bazi 33 ispitanika.

Iako prosječne vrijednosti valjanog inkluzivnog zaključivanja pokazuju porast iz mjerenja u mjerenje, u svim su mjerenjima prisutne velike interindividualne razlike. Totalni raspon u svim se mjerenjima kreće između 0% i 100%.



Slika 10. Prosječni postoci valjanih inkluzivnih zaključaka u četiri mjerenja

Kako bi se dobila još jasnija slika interindividualnih razlika, podaci o valjanosti inkluzivnih zaključaka su analizirani i frekvencijski (tablica 21). Kategorije su formirane prema kriteriju od 50% valjanih zaključaka koji se uobičajeno koristi kao pokazatelj uspješne strateške izvedbe na zadacima istraživačkog učenja (npr. kod Kuhn i Pearsall, 1998).

Tablica 21

Broj ispitanika u pojedinim kategorijama s obzirom na valjanost inkluzivnih zaključaka u četiri mjerenja

	Prvo mjerjenje <i>n</i>	Drugo mjerjenje <i>n</i>	Treće mjerjenje <i>n</i>	Četvrto mjerjenje <i>n</i>
Nema valjanih zaključaka	9	3	1	5
Neki valjani – manje od 50%	15	15	11	5
Neki valjani – 50% i više	8	6	11	9
Svi zaključci valjani	2	10	11	14
Nije donesen zaključak ove vrste	0	0	0	1

Iz tablice 21 je vidljivo da se od prvog do četvrtog mjerenja povećava broj učenika koji ostvaruju sve valjane zaključke, kao i da se (uglavnom) smanjuje broj učenika bez valjanih zaključaka. Međutim, na kraju istraživanja ostaje čak 10 učenika (30%) koji ostvaruju nezadovoljavajuću razinu valjanosti inkluzivnog zaključivanja.

Iz tablice se također može uočiti da većina učenika (25 ili 74%) donosi prvi valjani inkluzivni zaključak tijekom prvog mjerenja. Prvi valjani inkluzivni zaključak se zapravo javlja prosječno u šestom eksperimentu. Međutim, dva učenika donose takav zaključak već u drugom eksperimentu, sedam učenika u trećem, a četiri učenika u četvrtom eksperimentu prvog mjerenja.

Preostalih devet učenika (26%) koji nisu postigli valjane inkluzivne zaključke u prvom mjerenju, to ostvaruju tijekom drugog mjerenja (između 13. i 22. pokusa). U treće i četvrto mjerenje svi učenici ulaze s iskustvom donošenja valjanih inkluzivnih zaključaka.

Učenici koji postižu sve valjane zaključke u pojedinom mjerenju uglavnom valjano zaključuju i u sljedećim mjerenjima, ali ne uvijek. Primjerice, od 10 ispitanika koji imaju sve valjane inkluzivne zaključke u drugom mjerenju, samo njih četiri ima isto takav rezultat u trećem i četvrtom mjerenju, dok se ostali barem povremeno vraćaju i na nevaljano zaključivanje.

Zaključno, može se ustvrditi da tijekom rada na zadatku istraživačkog učenja dolazi do povećanja valjanosti inkluzivnog zaključivanja. To je povećanje uvjetovano padom u apsolutnom broju donesenih nevaljanih zaključaka ove vrste. Najveći porast valjanosti u prosječnim vrijednostima javlja se između prvog i drugog mjerenja, a maksimalna postignuta razina ostvaruje se već u trećem mjerenju.


Iako podaci sugeriraju značajno unaprjeđenje kapaciteta učenika za valjano utvrđivanje kauzalnih učinaka određenih nezavisnih varijabli, učenici završavaju rad na zadatku istraživačkog učenja uz postojanje značajnog prostora za daljnji razvoj ovih vještina.

#### *Valjanost ekskluzivnih zaključaka*

Valjanost ekskluzivnih zaključaka slijedi drugačiji obrazac od valjanosti inkluzivnih zaključaka. Prosječne su vrijednosti prikazane na slici 11. U prvom mjerenju učenici u prosjeku ostvaruju 75% valjanih ekskluzivnih zaključaka, u drugom mjerenju 71%, u trećem 76%, a u četvrtom 69%. Testiranje statističke značajnosti razlika u prosječnom postotku valjanih ekskluzivnih zaključaka između četiri mjerenja (na temelju rezultata 28

ispitanika koji su u sva četiri mjerenja donosili ekskluzivne zaključke) pokazuje da učinak 'rednog broja mjerenja' nije statistički značajan ( $\chi^2(3)=1,88, p=,602$ ).

Valjanost ekskluzivnih zaključaka je veća od valjanosti inkluzivnih zaključaka u prvom<sup>47</sup>, drugom<sup>48</sup> i trećem mjerenju ( $T_1=1,50, z=-4,38, p<,001, r=,57; T_2=11,44, z=-1,67, p=,096, r=,31, T_3=8,93, z=-2,50, p=,011, r=,31$ ), dok između prosječnih vrijednosti u četvrtom mjerenju nije dobivena statistički značajna razlika ( $T=12,96, z=-0,49, p=,632, r=,06$ ).



Slika 11. Prosječni postoci valjanih ekskluzivnih zaključaka u četiri mjerenja

Analiza broja učenika koji u pojedinom mjerenju ostvaruje određenu razinu valjanosti ekskluzivnog zaključivanja (prikazana u tablici 22) potvrđuje nalaze testiranja razlika u prosječnim vrijednostima između pojedinih mjerenja. Broj učenika u pojedinim kategorijama relativno je konstantan u različitim mjerenjima, jedino je opažen pad broja učenika koji uopće ne donose zaključke ove vrste.

<sup>47</sup> Testiranje razlika u valjanosti inkluzivnih i ekskluzivnih zaključaka je u prvom mjerenju provedeno na 30 ispitanika, u drugom na 31, u trećem na 32 i u četvrtom na 33 učenika. Razlike u broju ispitanika proizlazi iz činjenice da određeni broj ispitanika u pojedinom mjerenju nije donio niti jedan ekskluzivni zaključak.

<sup>48</sup> Opažena razlika između valjanosti ekskluzivnih i inkluzivnih zaključaka u drugom mjerenju nije statistički značajna, ali veličina učinka ukazuje na srednje veliki učinak.



Sve valjane ekskluzivne zaključke u pojedinim mjerenjima ostvaruje između 10 i 12 učenika (30 - 35% učenika), a broj učenika koji ostvaruje više od 50% valjanih zaključaka ove vrste također je znatan u svakom mjerenju (40 - 50% učenika).

Nezadovoljavajuću razinu valjanosti ekskluzivnih zaključaka pokazuje u pojedinom mjerenju tek manji dio ispitanika. Potrebno je, međutim, uočiti da je broj učenika s manje od 50% valjanih zaključaka veći u četvrtom nego u trećem mjerenju (8 prema 3 ispitanika). Kvalitativna analiza rada učenika na zadatku može ukazati na razloge takvog rezultata, iako je indikativan već i nalaz o tome da se među neuspješnim učenicima u četvrtom mjerenju nalaze dva učenika koji u prethodnim mjerenjima uopće nisu donosili ekskluzivne zaključke. Opažanje procesa eksperimentiranja kod učenika s niskom razinom valjanosti ekskluzivnog zaključivanja pokazuje da su neki od tih učenika koji su u prethodnim mjerenjima pokazivali sposobnost donošenja valjanih ekskluzivnih zaključaka, u sljedećim mjerenjima pokušavali demonstrirati nekauzalni status čimbenika 'konfiguracija tla' i 'udaljenost šuma od naselja' njihovim istovremenim zajedničkim variranjem iz eksperimenta u eksperiment. Na temelju zadržavanja istog ishoda eksperimenta (najmanjeg stupnja uništenja šuma) u kombinacijama u kojima su promijenjena oba čimbenika, ti su učenici točno (ali nevaljano) zaključivali da oba čimbenika nemaju veze s uništenjem šuma.

*Tablica 22*

Broj ispitanika u pojedinim kategorijama s obzirom na valjanost ekskluzivnih zaključaka u četiri mjerenja

	Prvo mjerenje <i>n</i>	Drugo mjerenje <i>n</i>	Treće mjerenje <i>n</i>	Četvrto mjerenje <i>n</i>
Nema valjanih zaključaka	2	2	0	2
Neki valjani – manje od 50%	3	5	3	6
Neki valjani – 50% i više	14	14	17	16
Svi zaključci valjani	11	10	12	10
Nije donesen zaključak ove vrste	4	3	2	0

Tablica 22 također pokazuje da velika većina učenika (28 ili 82%) donosi prvi valjani ekskluzivni zaključak tijekom prvog mjerenja. Prvi takav zaključak se u prosjeku javlja već u četvrtom pokusu, što se ne razlikuje statistički značajno od prvog pojavljivanja valjanog inkluzivnog zaključka ( $T=15,93$ ,  $z=-1,03$ ;  $p=,308$ ,  $r=,13$ ).

Ipak, manji dio učenika donosi prve valjane ekskluzivne zaključke znatno kasnije, zato što imaju problema s odbacivanjem vlastitih kauzalnih teorija o učinku 'udaljenosti šume od naselja' i 'konfiguracije tla'. Tri učenika donose prve valjane ekskluzivne zaključke tijekom drugog mjerenja (između 14. i 18. eksperimenta), jedan učenik tijekom trećeg mjerenja (u 23. eksperimentu), a jedan tek tijekom četvrtog mjerenja (u 40. eksperimentu). Jedan učenik, pak, tijekom cijelog eksperimentiranja nije donio niti jedan valjani ekskluzivni zaključak.

Također, potrebno je istaknuti da je za većinu učenika karakteristično pojavljivanje i valjanih i nevaljanih ekskluzivnih zaključaka u pojedinom mjerenju. Učenici koji u pojedinom mjerenju ostvaruju sve valjane ekskluzivne zaključke, u sljedećim se mjerenjima uglavnom, barem povremeno, vraćaju na nevaljano zaključivanje. Od 11 učenika koji su već u prvom mjerenju ostvarili sve valjane ekskluzivne zaključke, samo dvoje zadržava takvu razinu zaključivanja u sljedećim mjerenjima (i donose sve valjane ekskluzivne zaključke u sljedećim mjerenjima). Jednako tako, od 10 učenika koji ostvaruju 100% valjanost zaključivanja u drugom mjerenju, tek jedna polovina je jednako uspješna u sljedećim mjerenjima, dok druga polovina u trećem i četvrtom mjerenju ima i valjane i nevaljane zaključke ove vrste.

Na kraju, može se zaključiti da visoka početna razina valjanosti ekskluzivnih zaključaka (posebice u usporedbi s razinom valjanosti inkluzivnih zaključaka) sugerira da učenici nemaju problema u utvrđivanju nekauzalnog statusa određenih čimbenika. Međutim, nepostojanje napretka u donošenju valjanih zaključaka na razini grupnog prosjeka od prvog do četvrtog mjerenja, nekonzistentna uporaba valjanog zaključivanja kod učenika koji su već iskazali sposobnost potpuno valjanog zaključivanja u prethodnom mjerenju, kao i izbjegavanje donošenja ekskluzivnih zaključaka i kasno donošenje valjanih ekskluzivnih zaključaka kod jednog (manjeg) dijela učenika, govore o potrebi daljnjeg jačanja istraživačkih vještina i u ovom području.

#### *Valjanost interakcijskih zaključaka*

Na početku analize valjanosti interakcijskih zaključaka važno je navesti da tijekom cjelokupnog rada na zadatku, odnosno tijekom svih četiri mjerenja, šest učenika nije donijelo niti jedan interakcijski zaključak, a dodatnih devet učenika nije donijelo niti jedan valjani zaključak ove vrste. Dakle, ukupno je 28 učenika (82%) imalo interakcijske

zaključke, ali je samo 19 učenika (56% od ukupnog broja ispitanika) donijelo barem jedan valjani interakcijski zaključak.

Tek je 12 ispitanika donijelo interakcijske zaključke u sva četiri mjerenja. Zbog te je činjenice onemogućeno testiranje statističke značajnosti razlika u prosječnom postotku valjanih interakcijskih zaključaka između pojedinih mjerenja. Analiza valjanosti interakcijskih zaključaka i promjena tijekom rada na zadatku temelji se stoga na analizi deskriptivnih pokazatelja.

U prvom mjerenju učenici u prosjeku donose 0% valjanih interakcijskih zaključaka ( $C=0$ ,  $IQR=16,67$ ,  $n=18$ ). U drugom mjerenju ta prosječna vrijednost raste na 33% ( $C=33,33$ ,  $IQR=75$ ,  $n=17$ ), dok se u trećem i četvrtom mjerenju zadržava na niskoj razini od 17% i 13% ( $C_3=16,67$ ,  $IQR=100$ ,  $n=21$ ;  $C_4=12,50$ ,  $IQR=68,75$ ,  $n=24$ ).

Radi testiranja statističke značajnosti promjena u valjanosti interakcijskih zaključaka, podaci su dihotomizirani na učenike koji su u pojedinom mjerenju donijeli barem jedan valjani interaktivni zaključak i na učenike koji nisu donijeli niti jedan (valjani) interaktivni zaključak. Cochranovim testom za dihotomne zavisne podatke je utvrđeno da između prvog i četvrtog mjerenja raste broj učenika koji donose valjane interakcijske zaključke ( $Q(3)=9,46$ ,  $p=,029$ ).

Uz navedeno, utvrđeno je da valjani interakcijski zaključci pokazuju drugačiji obrazac prvog pojavljivanja od jednostavnih zaključaka. Pojavljuju se znatno kasnije nego prvi valjani inkluzivni ili ekskluzivni zaključak, prosječno u 22. eksperimentu. Najranije pojavljivanje prvog valjanog interakcijskog zaključka zabilježeno je u osmom eksperimentu. Uz tog ispitanika, još su tri učenika donijela svoj prvi valjani interakcijski zaključak tijekom prvog mjerenja (u 11. do 14. eksperimentu). Osam učenika donijelo je svoj prvi valjani interakcijski zaključak tijekom drugog mjerenja (između 15. i 26. eksperimenta), četiri učenika tijekom trećeg mjerenja (u 26. i 37. eksperimentu), a tri učenika tijekom zadnjeg mjerenja (u 39., 42. i 45. eksperimentu).

U tablici 23 prikazani su podaci o broju učenika u određenoj kategoriji s obzirom na donošenje valjanih interakcijskih zaključaka u četiri mjerenja.

Tablica 23

Broj ispitanika u pojedinim kategorijama valjanosti interakcijskih zaključaka u četiri mjerenja

	Prvo mjerenje	Drugo mjerenje	Treće mjerenje	Četvrto mjerenje
	<i>n</i>	<i>n</i>	<i>n</i>	<i>n</i>
Nema valjanih zaključaka	14	6	10	12
Neki valjani, neki nevaljani zaključci	3	8	5	7
Svi zaključci valjani	1	3	6	5
Nije donesen zaključak ove vrste	16	17	13	10

Iz tablice 23 se može vidjeti da je u svim mjerenjima prisutan značajan broj učenika koji ne ostvaruju niti jedan valjani interakcijski zaključak, kao i to da u drugom mjerenju (u odnosu na prvo) pada broj učenika bez valjanih zaključaka ove vrste. Svi navedeni podaci, sugeriraju da je valjanost interakcijskog zaključivanja na niskoj razini, unatoč opaženom povećanju broja učenika koji donose valjane zaključke ove vrste od prvog do četvrtog mjerenja.

Kvalitativna analiza procesa donošenja interakcijskih zaključaka kod nekoliko učenika – slučajeva, prikazana u drugom dijelu poglavlja «Rezultati i rasprava» ukazat će na neke čimbenike koji se nalaze u osnovi ovih nalaza.

#### **5.2.5. Jačanje istraživačkih vještina i strategija tijekom rada na zadatku: integracija rezultata i rasprava**

Prvo je poglavlje «Rezultata i rasprave» pokazalo da učenici na zadatku istraživačkog učenja, kroz samostalno eksperimentiranje i zaključivanje, stječu znanje o kauzalnoj strukturi modela zadatka. U ovom je poglavlju analizirano usporedno razvijanje istraživačkih vještina i strategija pomoću kojih učenici dolaze do tog znanja. Utvrđeno je da od prvog do četvrtog mjerenja učenici pokazuju napredak u korištenju istraživačkih vještina i strategija u svim fazama istraživačkog procesa.

Pri postavljanju istraživačkih pitanja i hipoteza opažen je rast planiranosti namjere izvođenja pojedinih eksperimenata i rast usmjerenosti učenika na analizu učinaka pojedinih čimbenika, kao i povećanje udjela eksperimenata s postavljenim hipotezama. Na početku istraživačkog učenja, inkluzivnih je hipoteza više nego ekskluzivnih (iako učenici u prosjeku postavljaju hipoteze tek u svakom trećem pokusu). Međutim, dok je broj inkluzivnih hipoteza stabilan kroz mjerenja, broj ekskluzivnih i interakcijskih hipoteza raste.

Pri eksperimentiranju nisu opažene promjene u mjerama pokrivanja prostora eksperimenata, ali se od prvog do četvrtog mjerenja smanjuje prosječan broj čimbenika mijenjanih po eksperimentu, što upućuje na porast sustavnosti eksperimentiranja i napredovanje u korištenju strategije kontrole varijabli.

Pri donošenju zaključaka nalazi se razlikuju ovisno o vrsti zaključaka. Na početku istraživačkog učenja učenici donose mnogo nevaljanih inkluzivnih zaključaka. Od prvog do četvrtog mjerenja izrazito pada broj inkluzivnih zaključaka donesenih po eksperimentu, a njihova valjanost raste, upravo uslijed pada broja nevaljanih zaključaka ove vrste.

Broj i valjanost ekskluzivnih zaključaka su stabilni kroz mjerenja. Na početku rada na zadatku učenici donose mnogo manje ekskluzivnih zaključaka nego inkluzivnih, ali je valjanost ekskluzivnih zaključaka tada značajno veća. Od prvog do četvrtog mjerenja ujednačuje se broj i valjanost ekskluzivnih i inkluzivnih zaključaka. U zadnjem mjerenju čak je više ekskluzivnih nego inkluzivnih zaključaka po eksperimentu, ali se oni međusobno ne razlikuju po stupnju valjanosti.

Nalazi o različitim obrascima razvoja inkluzivnog i ekskluzivnog zaključivanja u situacijama ponavljanog rada na zadacima istraživačkog učenja, odnosno nalazi o većoj brojnosti inkluzivnih hipoteza i zaključaka, te o njihovoj manjoj valjanost u početnim fazama istraživačkog učenja uobičajeni su nalazi istraživanja u ovom području (Kuhn i sur., 1992, 1995; Schauble, 1990, 1996). Kuhn i suradnici (1995) te nalaze povezuju s nevaljanim istraživačkih pristupima učenika, te s različitim mogućnostima donošenja inkluzivnih i ekskluzivnih zaključaka u multivarijantnim zadacima. Naime, nekontrolirana usporedba eksperimenata češće dovodi do razlika u ishodima, nego do jednakih ishoda, s obzirom da je malo vjerojatno da će se učinci pojedinih čimbenika kompenzirati na način da se ostvare upravo jednaki rezultati u različitim eksperimentima. Stoga nekontrolirana usporedba pruža više mogućnosti za donošenje inkluzivnih zaključaka, nego ekskluzivnih. Osim toga, donošenje generaliziranog zaključka je mnogo jednostavnije kad se radi o kauzalnim učincima, nego o njihovom nepostojanju, budući da je u skupu eksperimenata koji nisu provedeni na kontrolirani način mnogo lakše uočiti kovarijaciju nego nepostojanje kovarijacije. Zbog tih razloga, učenici imaju veću mogućnost generirati nalaze koji podržavaju kauzalne zaključke. Osim toga, uz kauzalne se teorije veže veća kognitivna i afektivna vrijednost, pa su učenici pri interpretiranju nalaza više usmjereni na čimbenike koje smatraju kauzalnima. Veća prisutnost kauzalnih zaključaka je time vezana uz pojavu pristranosti potvrđivanja (Dunbar i Klahr, 1989; Klahr i Carver, 1995), koja

predstavlja sklonost učenika da u izboru eksperimenata i vrednovanju nalaza daju prednost onim eksperimentima i nalazima koji potvrđuju njihove hipoteze i teorije, dok se nekauzalni čimbenici ignoriraju. Kauzalne teorije je lako stvoriti čak i kad ih učenici ne očekuju, zato što tijekom eksperimentiranja stvaraju mnogo prilika za donošenje upravo takvih zaključaka na temelju generiranih ograničenih nalaza.

Osim deficitima u strateškim aspektima istraživačkog učenja, usmjerenost na kauzalne zaključke interpretira se općenitom većom salijentnošću prisustva nego odsustva nečeg (Kuhn i sur., 1992), većim iskustvom i većom mogućnošću uvježbavanja u donošenju inkluzivnih zaključaka u svakodnevnom životom (Schauble, 1996), kao i većom usmjerenosti na relevantne (kauzalne) čimbenike unutar prirodoslovnog obrazovanja (Kanari i Millar, 2003).

Ova se objašnjenja razlika između inkluzivnog i ekskluzivnog zaključivanja mogu primijeniti i na slučaj ovog istraživanja. Prve situacije rada na istraživačkom zadatku bile su obilježene velikim brojem nevaljanih inkluzivnih zaključaka o čimbenicima 'učestalost padanja kiselih kiša' i 'pojava nametnika' koje su učenici nedvojbeno smatrali kauzalnim čimbenicima, a najveći napredak u zaključivanju očitovao se upravo u inhibiranju donošenja tih zaključaka. Međutim, za razliku od drugih istraživanja (Kuhn i sur., 1992, 1995; Schauble, 1996), u ovom istraživanju nije bilo značajnijeg rasta valjanosti ekskluzivnih zaključaka, vjerojatno zato što je relativno visoka razina strateškog postignuća u ovom području postignuta već u prvom mjerenju.

Usprkos napredovanju u različitim istraživačkim vještinama i strategijama tijekom rada na zadatku na razini cijele skupine učenika, rezultati istraživanja ukazuju na značajne interindividualne razlike. U svim se mjerenjima, uz sve mjere vežu velika raspršenja rezultata. Dok se na jednom ekstremu nalaze učenici koji već na početku rada na zadatku iskazuju orijentiranost na ispitivanje pojedinih čimbenika, više-manje sustavno eksperimentiraju i donose uglavnom valjane inkluzivne i ekskluzivne zaključke (te poneke interakcijske zaključke), na drugom ekstremu su učenici koji do kraja istraživanja eksperimentiraju s ciljem generiranja pojedinih ishoda, ne postavljaju hipoteze, uglavnom ne koriste strategiju kontrole varijabli i većim dijelom nevaljano zaključuju o odnosima između nezavisnih i zavisnih varijabli. Između tih krajnih primjera, nalazi se većina učenika koji slijede različite obrasce napredovanja prema višim razinama strateškog djelovanja, a koje karakterizira korištenje i valjanih i nevaljanih, i učinkovitih i manje neučinkovitih istraživačkih pristupa, vještina i strategija.

Rezultati istraživanja također sugeriraju da se u većini ispitanih mjera napredak u korištenju istraživačkih vještina i strategija očituje tijekom prve dvije situacije učenja, dok se već u trećem mjerenju uspostavlja konačna razina. Ta je razina, ipak, daleko od optimalne. Čak i u zadnjem mjerenju učenici izvode mnogo eksperimenata bez prethodnog izražavanja vlastitih očekivanja (bez postavljanja hipoteza), a doneseni jednostavni zaključci (i inkluzivni i ekskluzivni) su i dalje značajnim dijelom doneseni na nevaljani način, na temelju usporedbe nekontroliranih eksperimenata. Pokazuje se da učenici ne uspijevaju konzistentno koristiti valjane strategije eksperimentiranja i zaključivanja, iako su tijekom rada na zadatku pokazali sposobnost njihovog korištenja (barem) u nekim situacijama. Poseban problem za učenike predstavlja otkrivanje interakcijskih odnosa između varijabli. Iako većina učenika ima iskustvo donošenja takvih zaključaka, neki učenici uopće ne uviđaju mogućnost da učinak određenog čimbenika može biti ograničen ili različit na drugim razinama drugih varijabli. Prosječan broj interakcijskih zaključaka po eksperimentu je stoga malen, a niti se ne mijenja iz mjerenja u mjerenje. Valjanost interakcijskih zaključaka je niska kroz sva četiri mjerenja, usprkos nalazu o povećanju broja učenika koji su donijeli barem jedan valjani interakcijski zaključak od prvog do četvrtog mjerenja.

Postavlja se pitanje: Zašto su se učenici zaustavili u napredovanju na zadatku već u trećem mjerenju, odnosno zašto nisu više napredovali u korištenju valjanih strategija eksperimentiranja i zaključivanja?

Jedno od mogućih odgovora na ovo pitanje veže se uz činjenicu da se rad na zadatku istraživačkog učenja odvijao bez jasne povratne informacije o postignućima učenika, koja bi učenike informirala o tome koliko ostvaruju ciljeve na zadatku i kako napreduju. Učenici su, doduše, nakon svakog provedenog eksperimenta, mogli vidjeti stvaran rezultat uništenja šuma za odabranu kombinaciju čimbenika i usporediti ga s predviđenim rezultatom. To jest povratna informacija na temelju koje su učenici mogli steći dojam o svojem postignuću, međutim, izravna informacija o točnosti učeničkih očekivanja ili njihovih zaključaka o kauzalnoj strukturi modela zadatka nije postojala. Može se pretpostaviti da bi uvođenje takve povratne informacije značajno unaprijedilo učenje kroz pružanje mogućnosti vrednovanja i traženja novih istraživačkih pristupa, ali i kroz njezino eventualno motivacijsko djelovanje (služenjem kao poticaj za ulaganje truda i održavanje usmjerenosti na ovladavanje zadatkom).

U situaciji kad ne postoji povratna informacija o točnosti učeničkih teorija i zaključka, a nema ni direktne poduke o istraživačkim pristupima i procesima, može se pretpostaviti da je opaženo napredovanje u strateškom djelovanju učenika na zadatku istraživačkog učenja vezano uz nekoliko elemenata. Kao prvo, kao što navode Kuhn i suradnici (Kuhn i Phelps, 1982; Kuhn, 1995; Kuhn i sur., 1995) u situacijama u kojima se učenici višekratno izlažu situacijama koje od njih zahtijevaju primjenu istraživačkih vještina i strategija, već samo vježbanje postojećih vještina i strategija može biti dovoljno za njihovo postupno mijenjanje. Kao drugo, informacije o stvarnom stupnju uništenja šuma koje nastaju kao rezultat učeničkog djelovanja na zadatku istraživačkog učenja mogu potaknuti učenje. Kvalitativno opažanje rada na zadatku pokazalo je da su učenici često temeljili interpretaciju nalaza pojedinih eksperimenata, ali i odluku o provođenju sljedećeg eksperimenta upravo na razlici predviđenog i stvarnog stupnja uništenja šuma u tom (prethodnom) eksperimentu.

Kao treće, napredovanje učenika u strateškoj izvedbi na zadatku istraživačkog učenja dovodi se u vezu s istraživačkom procedurom, odnosno s činjenicom da se tijekom rada na zadatku učenicima postavljaju pitanja o procesu rada, kao i da se od njih zahtijeva da «misle naglas». Naime, iako se učenicima ne sugeriraju mogući (ili poželjni) pristupi radu niti daju povratne informacije o znanju i strategijama koje su stekli na zadatku, tijekom provođenja svakog eksperimenta učenici se ispituju o tome što rade i što misle u pojedinim fazama istraživačkog procesa.

Pretpostavlja se da postavljanje pitanja učenicima i korištenje «misli naglas» protokola predstavlja poticaje koji mogu djelovati na poboljšanje strateškog djelovanja učenika. Iako je njihova primarna svrha osiguravanje podataka o učeničkim planovima, namjerama, očekivanjima, strateškim izborima, zaključcima i objašnjenjima zaključaka, ti se poticaji mogu shvatiti kao implicitan trening istraživačkih vještina (Chen i Klahr, 1999), odnosno kao suptilno instruiranje učenika koje aktivira razumijevanje ciljne strukture koja je u podlozi valjanog zaključivanja i koordiniranja teorija i nalaza (Klahr i Carver, 1995). Pitanja koja postavlja istraživač mogu služiti kao znakovi o strateških zahtjevima zadatka, a mogu i poticati samoobjašnjenja ili refleksiju koja može inducirati metastratešku svjesnost zahtjeva zadatka (Zimmerman, C. 2005). Pitanja mogu usmjeriti pažnju učenika na informacije na koje inače ne bi obraćao pažnju, te ih potaknuti na refleksivno mišljenje (Wilhelm i Beishuizen, 2004). Korištenje glasnog razmišljanja, zbog nametanja potrebe verbalizacije misli, također može naglasiti kognitivne aspekte zadatka i stvoriti okruženje u



kojem učenici više razmišljaju o zahtjevima zadatka, biraju učinkovitije sustavne pristupe radu na zadatku i dublje procesiraju nalaze koje generiraju (Vollmeyer i Rheinberg, 1999, 2005).

Konačno, rezultati ovog istraživanja, kao i drugih mikrorazvojnih istraživanja istraživačkog učenja (npr. Kuhn i sur., 1992, 1995; Schauble, 1996) pokazuju da su navedeni poticaji nedovoljni za stjecanje potpunog znanja o kauzalnoj strukturi modela zadatka, kao i za uspostavljanje obrazaca konzistentnog korištenja valjanih strategija eksperimentiranja i zaključivanja. Tome zasigurno pridonosi složenost korištenog zadatka istraživačkog učenja, koji pred učenike postavlja izazove koordinacije različitih strateških, metastrateških i metakognitivnih procesa, a ujedno nudi slobodu u izboru istraživačkog pristupa i u donošenju odluka o broju, rasporedu i vrsti eksperimenata koji će se provesti i zaključaka koji će se donijeti. U takvim uvjetima odvijanja zadatka, može se očekivati da će rezultati učenja biti izrazito ovisni o tome koliko učenik uspješno samoregulira vlastite procese učenja, kakvi su mu metakognitivni kapaciteti za praćenje i upravljanje vlastitim učenjem, kao i motivacijska spremnost za započinjanje i zadržavanje aktivnosti učenja. O ovim će aspektima istraživačkog učenja biti riječi u sljedećim poglavljima.

### **5.3. Jačanje metakognitivnih vještina i povezanost s istraživačkim vještinama i strategijama i učinkom na zadatku**

Ovo poglavlje, koje daje prikaz rezultata o korištenju metakognitivnih vještina planiranja i praćenja rada na zadatku istraživačkog učenja, predstavlja jedan dio odgovora na drugi istraživački problem: *Kakva je povezanost metakognitivnog znanja i metakognitivnih vještina s istraživačkim vještinama i učinkom na zadatku istraživačkog učenja?* Drugi dio odgovora, onaj o stjecanju metakognitivnog znanja, dat je u sljedećem poglavlju.

#### **5.3.1. Planiranje i organiziranje rada na zadatku istraživačkog učenja**

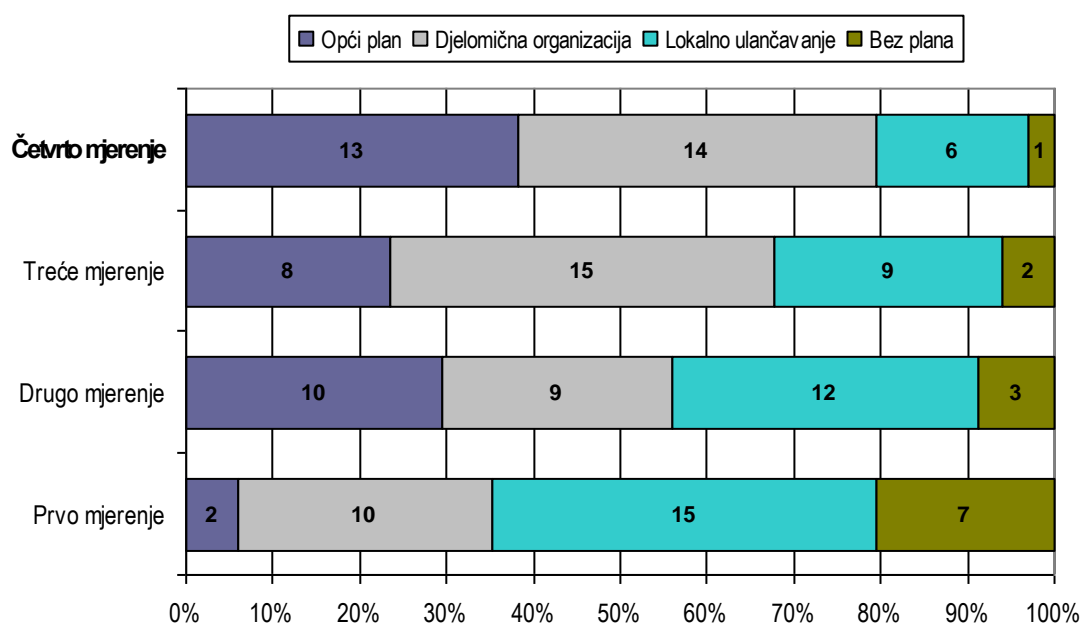
Zbog složenosti i međusobne zavisnosti različitih aktivnosti i procesa uključenih u rad na zadatku istraživačkog učenja, za ostvarivanje uspjeha na tome zadatku ključno je planirati i organizirati proces eksperimentiranja na sustavan način. Stoga je u ovom poglavlju provjereno napreduju li učenici tijekom rada na zadatku u planiranju i organizaciji vlastitih istraživačkih aktivnosti, kao i to koliko je to povezano s učinkom koji postižu na zadatku.

Učenički verbalni protokoli koji su prikupljeni tijekom rada na zadatku ocijenjeni su s obzirom na to koja je razina planiranja i organiziranja rada ostvarena. Na slici 12 prikazan je broj učenika koji ostvaruje određenu razinu plana u četiri mjerenja.

Tijekom prve situacije rada na zadatku kod najvećeg broja učenika (15, ili 44%) prisutno je tzv. lokalno ulančavanje, za koje je tipično povezivanje susjednih parova eksperimenata i njihova izolirana usporedba, bez postojanja uvida u širu strukturu problema (prostora eksperimenata), kao i bez razumijevanja potrebe sustavnog i organiziranog djelovanja na zadatku. Najvišu razinu planiranja, opći plan, koji vodi učenike u provedbi cijelog skupa eksperimenata, koristilo je tek dvoje učenika (6%), dok je 10 učenika (29%) raspolagalo djelomično organiziranim planom. Potpuno neplanski pristup eksperimentiranju u prvom mjerenju pokazalo je sedam učenika (21%).

Od prvog do četvrtog mjerenja dolazi do značajne promjene u razini korištenih planova ( $\chi^2(3)=29,93, p<,001$ ). Post hoc analizom razlika između susjednih mjerenja utvrđena je statistički značajna razlika između prvog i drugog mjerenja ( $T_{1,2}=8,00, z=-3,38, p<,001, r=,41$ ). Povećava se broj učenika s općim planom, a smanjuje broj učenika koji radu na zadatku pristupaju neplanski i nesustavno.

Razlika između drugog i trećeg mjerenja nije statistički značajna ( $T_{2,3}=8,14$ ,  $z=-0,61$ ,  $p=,627$ ,  $r=,07$ ), kao ni razlika između trećeg i četvrtog mjerenja ( $T_{3,4}=6,50$ ,  $z=-2,50$ ,  $p=,020$ ,  $r=,30$ ), iako veličina učinka ovdje ukazuje na srednju veličinu. Takav nalaz upućuje na zaključak o daljnjem porastu broja učenika koji rad na zadatku istraživačkog učenja provode po općem planu u zadnjem mjerenju. U skupinu učenika s najvišom razinom planiranja tada je kategorizirano 13 učenika (38%).



Slika 12. Broj ispitanika s određenom razinom planiranja rada na zadatku u četiri mjerenja

Kvalitativna analiza procesa rada kod učenika koji se vode općim planom pokazuje da su oni najčešće rad na zadatku organizirali tako da su eksperimentiranje započeli zadavanjem kombinacije koja označava minimalno zagađenje, a potom su ispitivali jedan po jedan čimbenik, uglavnom redosljedom koji je zadan FILE programom. Neki od učenika koji su posjedovali opći plan za rad na zadatku, eksperimentiranje su započeli ispitivanjem učinka pojedinih čimbenika unutar kategorije 'bjelogorična šuma', a zatim su nastavili ispitivanje utvrđivanjem utjecaja tih čimbenika unutar druge kategorije šuma, unutar 'crnogoričnih šuma'.

U posljednjem mjerenju, uz kategoriju 'opći plan', najbrojnija kategorija učenika je ona čiji se rad može okarakterizirati kao djelomična organizacija (41%). Za ove je učenike tipično da su rad na zadatku započinjali imajući u vidu opću strukturu problema i potrebu sustavnog ispitivanja čimbenika, međutim, tijekom rada ih je neki (neočekivan ili

neobičan) eksperimentalni rezultat ili neka nova ideja odvratili od prvobitnog plana i potpuno sustavnog i organiziranog rada na zadatku.

Ispitano je razlikuju li se učenici koji dosežu određenu razinu plana u četvrtom mjerenju<sup>49</sup> po korištenju istraživačkih strategija i vještina i po učinku na zadatku. U analizi je izostavljena skupina 'bez plana', budući da se u njoj nalazila samo jedna ispitanica.

U tablici 24 prikazane su centralne vrijednosti pojedinih pokazatelja učinka na zadatku i istraživačkih vještina i strategija u četvrtom mjerenju kod skupina učenika koji postižu različitu razinu planiranja u tom mjerenju.

*Tablica 24*

Prosječne vrijednosti (centralne vrijednosti) pojedinih pokazatelja učinka na zadatku i istraživačkih vještina i strategija u četvrtom mjerenju kod učenika koji postižu različitu razinu plana na zadatku

	Opći plan	Djelomična organizacija	Lokalno ulančavanje	Bez plana
Broj učenika	13	14	6	1
Točnost teorija o odnosima varijabli	10	8	7	2
Prosječna pogreška predviđanja rezultata eksperimenata	,22	,33	,48	,50
Postotak eksperimenata s nejasnim planom	0,00	8,40	8,85	50,00
Postotak eksperimenata bez hipoteze	21,59	40,00	85,45	90,00
Prosječan broj čimbenika mijenjan po eksperimentu	1,67	1,96	2,39	4,11
Valjanost jednostavnih zaključaka	71,43	73,21	37,50	0,00

Rezultati testiranja razlika između skupina učenika koje postižu različitu razinu planiranja i organiziranja rada na zadatku pokazuju statistički značajne razlike u točnosti učeničkih teorija o odnosima između varijabli ( $H(2)=8,48$ ,  $p=,014$ ), u postotku eksperimenata provedenih bez hipoteze ( $H(2)=17,34$ ,  $p<,001$ ), korištenju strategije kontrole varijabli ( $H(2)=8,49$ ,  $p=,014$ ), i valjanosti jednostavnih zaključaka ( $H(2)=5,89$ ,  $p=,053$ ). Razlike u prosječnoj pogreški predviđanja i postotku eksperimenata provedenih s nejasnim planom nisu statistički značajne ( $H_{ppp}(2)=5,04$ ,  $p=,081$ ;  $H_{plan}(2)=5,66$ ,  $p=,059$ ), iako su u očekivanom smjeru.

Učenici koji postižu višu razinu planiranja na zadatku istraživačkog učenja ostvaruju bolji učinak i po stečenom znanju i po strateškom djelovanju na zadatku - oni provode veći broj

<sup>49</sup> U analizi su korišteni rezultati iz četvrtog, zadnjeg mjerenja, zato što oni predstavljaju konačan ishod ili rezultat istraživačkog učenja koji su učenici postigli na zadatku. Pokazuje se da analize prvog, drugog i trećeg mjerenja daju jednake rezultate, koji ovdje nisu prikazani zbog ograničenja opsega rada.

eksperimenata s postavljenim hipotezama, češće koriste strategiju kontrole varijabli odnosno sustavnije eksperimentiraju, donose valjanije zaključke i posjeduju veće znanje o kauzalnoj strukturu modela zadatka.

U Prilogu u tablici 14 prikazani su rezultati post hoc testiranja između skupina.

Utvrđeno je da se učenici koji na zadatku istraživačkog učenja rade po općem planu ne razlikuju statistički značajno po ispitivanim pokazateljima od učenika koji rade djelomično organizirano. Ipak, veličine učinaka u visini od  $r=,30$  do  $r=,45$  ukazuju na to da učenici s općim planovima ipak ostvaruju pozitivnije rezultate na svim mjerama, osim na točnosti učeničkih teorija o učincima nezavisnih varijabli.

U odnosu na učenike koji lokalno ulančavaju eksperimente, učenici s općim planovima ostvaruju bolje rezultate na svim mjerama.

Dobivene su i statistički značajne razlike između učenika koji djelomično organiziraju svoj rad na zadatku i učenika za koje je karakteristično lokalno ulančavanje. Prva skupina učenika postavlja veći broj eksperimenata s hipotezama i pokazuje veću točnost teorija o odnosima između varijabli od druge skupine. U ostalim mjerama nisu utvrđene statistički značajne razlike između ovih skupina.

### ***5.3.2. Korištenje funkcija programa FILE i vođenje bilježaka tijekom rada na zadatku***

Program FILE posjeduje nekoliko funkcija koje pomažu učenicima u praćenju procesa eksperimentiranja u zadatku istraživačkog učenja. To su funkcije:

- pomicanje u prozoru gore-dolje
- selekcija eksperimenata
- organizacija eksperimenata

Pomicanje u prozoru gore-dolje omogućuje vraćanje pogleda na već provedene eksperimente, kad je provedeno više od četiri eksperimenata. Korištenje te funkcije sugerira namjeru učenika da provjeri postavljanje prijašnjih eksperimenata i poveže ishode različitih eksperimenata.

Selekcija eksperimenata nudi izdvajanje nekoliko eksperimenata u novi prozor, čime se olakšava njihova usporedba i zaključivanje. Prednosti korištenja funkcije selekcije dolaze do izražaja posebice pri utvrđivanju složenih međuosnosa varijabli tj. pri zaključivanju o interakcijskim ili nelinearnim odnosima između varijabli.

Organizacija eksperimenata omogućava mijenjanje redoslijeda napravljenih eksperimenata u prozoru, čime olakšava usporedbu udaljenih eksperimenata. Ova funkcija dozvoljava i mijenjanje redoslijeda varijabli unutar pojedinih eksperimenata, čime može pomoći učenicima koji pojedine nezavisne varijable nisu zadavali po nekom fiksnom redoslijedu (definiranom programom ili individualnim pristupom učenika)<sup>50</sup>.

Imajući na umu da sve opisane funkcije programa FILE omogućuju učeniku praćenje vlastitog procesa rada na zadatku istraživačkog učenja, kao i provjeru i organiziranje nalaza koji su stvoreni putem eksperimentiranja, može se reći da je korištenje tih funkcija pokazatelj učeničke uporabe metakognitivnih vještina.

Učenici su s funkcijama programa FILE upoznati u više situacija. Na prvom grupnom sastanku na kojem im je predstavljen zadatak o Petru koji kasni u školu pokazane su im sve mogućnosti programa, te su im objašnjene prednosti koje korištenje tih funkcija donosi. Tijekom prvih individualnih sastanaka, u okviru predstavljanja zadatka o uništenju šuma, učenicima je ponovno skrenuta pažnja na funkcije programa kao na one koje im mogu pomoći u radu. Prije početka rada u svim sljedećim mjerenjima učenicima je ponovno spomenuto da se pri radu na zadatku mogu koristiti navedenim funkcijama. U svim mjerenjima, učenicima je ponuđena i mogućnost vođenja bilježaka o provedenim eksperimentima, njihovim rezultatima i vlastitim zaključcima. Korištenje te «vanjske memorije» također pruža mogućnost olakšanog praćenja rada na zadatku. Za svakog je ispitanika pripremljen bijeli papir i olovka koji su stajali neposredno uz računalo.

U nastavku je prikazano koliko su učenici koristili opisane mogućnosti programa FILE, kao i vođenje bilježaka.

*Tablica 25*

Broj učenika koji su koristili pojedinu funkciju programa FILE i vođenje bilježaka u četiri mjerenja

	Pomicanje u programu gore - dolje	Selekcija	Organizacija	Vođenje bilježaka
	<i>n</i>	<i>n</i>	<i>n</i>	<i>n</i>
Prvo mjerenje	23	0	5	1
Drugo mjerenje	26	5	5	1
Treće mjerenje	25	1	3	0
Četvrto mjerenje	20	1	3	0

<sup>50</sup> Analiza učeničkih protokola pokazuje da su učenici pri radu slijedili redoslijed varijabli kakav je zadan programom. Gotovo uvijek eksperimenti su konstruirani sljedećim redoslijedom: prvo je izabirana sličica za čimbenik 'vrsta drveća u šumi', pa za 'konfiguraciju tla', pa 'udaljenost šume od naselja', pa 'učestalost pojave kiselih kiša', pa 'pojavu nametnika'. Tek su u par situacija ispitanici pri biranju čimbenika za pojedini eksperiment mijenjali ovaj redoslijed.

Iz tablice 25 koja prikazuje broj učenika koji su koristili pojedine funkcije programa FILE, kao i vođenje bilježaka, može se vidjeti da su one korištene od strane vrlo malog broja ispitanika.

Jedino se pomicanje u prozoru programa gore-dolje izdvaja kao funkcija koju je u svakom mjerenju koristilo 60 – 70% učenika. Osim bilježenja korištenja ove funkcije (da-ne), za tu je mjeru zabilježena i frekvencija korištenja unutar pojedinog mjerenja. Utvrđeno je da je pomicanje gore-dolje u prozoru programa izvedeno u prosjeku 2-3 puta po mjerenju (od strane učenika koji su koristili ovu funkciju). Po učestalosti korištenja ove funkcije nema statistički značajne razlike od prvog do četvrtog mjerenja ( $\chi^2(3)=4,27, p=,233$ ).

Veće korištenje funkcije 'pomicanja gore-dolje' u odnosu na druge ponuđene funkcije, zasigurno je posljedica činjenice da je ta funkcija sastavni dio svih računalnih programa s kojima se učenici uobičajeno susreću u svakodnevnom životu, pa je njezino korištenje gotovo automatizirano. S druge strane, organizacija i selekcija eksperimenata su funkcije specifične za program FILE, pa i njihova uporaba nije toliko uvriježena. Uz to, moguće je da učenici nisu bili svjesni koristi koje bi im pružilo korištenje ovih programskih funkcija za vrijeme rada na zadatku, kao i to da podcjenjuju zahtjeve zadatka i njegovu složenost (o čemu, kao što će poslije biti izloženo, govore podaci o malom osjećaju težine zadatka koji je dominantno prisutan kod učenika već od početka rada na zadatku).

Tek je jedan ispitanik iskoristio mogućnost vođenja bilježaka i u dva mjerenja zapisao rezultate eksperimenata koje je proveo i vlastite zaključke. Takvo iznimno malo korištenje bilježaka potvrđuje nalaze drugih istraživanja koja kažu da djeca u osnovnoškolskoj dobi rijetko spontano vode bilješke, uglavnom zato što nisu svjesna ograničenja vlastitog pamćenja i nemaju dostatno razvijenu metamemoriju (Zimmerman, C. 2005). Iako korištenje zabilješki olakšava rad na istraživačkom zadatku i osigurava da se rad na zadatku temelji više na rezoniranju i rješavanju problema nego na pamćenju (Zimmerman, 2007), učenici nisu svjesni koristi koje donosi vođenje bilježaka.

Analizirana je povezanost korištenja navedenih funkcija FILE-a i učinka na zadatku istraživačkog učenja. U tu je svrhu formirana nova varijabla 'korištenje metakognitivnih vještina praćenja', zbrajanjem broja funkcija programa koje je ispitanik koristio u pojedinom mjerenju. Takav je postupak opravdan pod pretpostavkom da pojedina specifična metakognitivna ponašanja imaju zajednički temelj, odnosno da pojedine funkcije programa o kojima je ovdje riječ služe istoj svrsi (praćenju procesa rada, praćenju

napredovanja na zadatku, provjeri rezultata rada, otkrivanju pogrešaka, radi lakšeg uspoređivanja postignutih rezultata i usmjeravanja istraživačkih aktivnosti) i pružaju slične mogućnosti pregleda rezultata na različite načine.

Nova formirana mjera nije uzimala u obzir učestalost korištenja pojedinih funkcija, već se temeljila na dihotomnim podacima (korišteno/ nije korišteno). Vrijednosti nove mjere kreću se od 0 (ukoliko nije korištena niti jedna funkcija programa) do 3 (ukoliko su korištene sve tri funkcije programa).

Između četiri mjerenja nije utvrđena statistički značajna razlika u prosječnom broju korištenih funkcija programa ( $\chi^2(3)=5,84, p=,119$ ).

U tablici 26 prikazani su koeficijenti Kendallove Tau korelacije između korištenja funkcija programa i učinka na zadatku iskazanog kroz točnost teorija učenika o odnosima između varijabli u modelu zadatka i kroz pogrešku predviđanja rezultata eksperimenata.

*Tablica 26*

Koeficijenti Kendallove Tau korelacije između metakognitivnih vještina praćenja i točnosti teorija učenika o odnosima između varijabli i pogreške predviđanja rezultata eksperimenata

	Pogreška predviđanja rezultata eksperimenata	Točnost teorija učenika o odnosima varijabli
	$\tau$	$\tau$
Prvo mjerenje	-,32*	-,03
Drugo mjerenje	-,35*	,04
Treće mjerenje	-,07	,20
Četvrto mjerenje	,09	,20

\*  $p < ,05$

Korištenje funkcija FILE programa nije povezano s točnošću teorija učenika o učincima pojedinih čimbenika na uništenje šuma niti u jednom mjerenju, ali je u prva dva mjerenja negativno povezano s prosječnom pogreškom predviđanja rezultata eksperimenata. To znači da je korištenje (većeg broja) funkcija povezano s manjom pogreškom predviđanja rezultata eksperimenata. Kvalitativni podaci dobiveni opažanjem rada učenika na zadatku upravo i govore o tome da su učenici često koristili navedene funkcije programa upravo u trenutku kad su trebali predvidjeti rezultat eksperimenta koji su upravo provodili, stoga im je praćenje rada na zadatku korištenjem navedenih funkcija moglo pomoći u točnijem predviđanju. Može se pretpostaviti da su se u kasnijim mjerenjima učenici pri predviđanju rezultata eksperimenata češće koristili pamćenjem (prethodnih rezultata iz istog i prethodnih mjerenja) nego neposrednim praćenjem rada.



### **5.3.3. Metakognitivne vještine: integracija rezultata i rasprava**

U skladu s poimanjem metakognitivnih vještina kao proceduralnog znanja potrebnog za stvarnu regulaciju i kontrolu procesa učenja, u istraživanju je utvrđena razina planiranja koju su učenici koristili pri radu na zadatku i zabilježeno korištenje FILE-ovih programskih funkcija koje upućuju na aktivne pokušaje učenika da usporede podatke iz različitih eksperimenata i da organiziraju eksperimente na način koji im olakšava povezivanje prostora hipoteza i prostora eksperimenata (Wilhelm i sur., 2005). Korištenje ograničenog broja mjera metakognitivnih vještina u istraživanju vezuje se uz pretpostavku o mogućnosti da mali broj mjera prikladno reprezentira širi skup metakognitivnih vještina (Veenman i sur., 2004; Veenman i Spaans, 2005). Ta se pretpostavka temelji na empirijskim nalazima o visokoj međuzavisnosti različitih manifestacija metakognitivnih vještina (Veenman, Elshout i Meijer, 1997). Veenman i suradnici (2004) su, primjerice, utvrdili visoku povezanost korištenja funkcije pomicanja gore-dolje u prozoru FILE programa (kao pozitivnog pokazatelja metakognitivnih vještina) i korištenja strategije kontrole varijabli (prosječnog broja čimbenika mijenjanih po eksperimentu kao negativnog pokazatelja tih vještina), te dobili visoku povezanost zajedničke mjere ovih metakognitivnih vještina i procjene kvalitete metakognitivnih aktivnosti na temelju «misli naglas» protokola.

Istraživanja koja ispituju povezanost metakognitivnih vještina i učenja uglavnom koriste mali broj metakognitivnih mjera, ali, na takav način, ne mogu jasno odrediti koje (specifične) metakognitivne aktivnosti su povezane s pozitivnim rezultatima učenja (Meijer, Veenman i Van Hout-Wolters, 2006).

Ovo istraživanje ukazuje na mogućnost da različite manifestacije metakognitivnih vještina nisu dio jedinstvenog, općeg metakognitivnog sklopa. Korištene mjere metakognitivnih vještina, planiranje rada na zadatku i pomicanje u prozoru programa gore-dolje, međusobno ne koreliraju visoko (kontingencijski koeficijenti se kreću između ,18 u trećem i ,42 u drugom mjerenju i nisu statistički značajni). O različitosti ispitivanih metakognitivnih aktivnosti govori i činjenica da tijekom rada na zadatku dolazi do napredovanja učenika u razini planiranja rada (budući da se učenici s lokalnog ulančavanja pomiču prema organiziranju šireg prostora eksperimenata i korištenju općih planova), dok nema promjena u korištenju FILE-ovih programskih funkcija. Također, različiti obrasci povezanosti ovih metakognitivnih mjera s drugim, vanjskim mjerama upućuju na različite funkcije koje ove specifične metakognitivne aktivnosti obavljaju na zadatku istraživačkog

učenja. Naime, pokazuje se da je planiranje rada na zadatku povezano s točnošću učeničkih teorija o učinku pojedinih čimbenika na uništenje šuma (i s nizom drugih pokazatelja korištenja istraživačkih vještina i strategija), dok je korištenje FILE-ovih programskih funkcija povezano s točnošću predviđanja rezultata eksperimenata, ali ne i s točnošću učeničkih teorija. Utvrđene razlike među ovim metakognitivnim mjerama mogu se povezati i s činjenicom da one zahvaćaju metakognitivne aktivnosti na različitim razinama općenitosti/ specifičnosti. Dok je planiranje rada na zadatku šira i sveobuhvatnija mjera, koja uzima u obzir cjelokupni rad na zadatku u pojedinoj situaciji istraživačkog učenja, i koja, kao takva, nije usko vezana uz prirodu zadatka, već je primjenjiva na različitim zadacima, korištenje FILE-ovih programskih funkcija predstavlja metakognitivne aktivnosti koje su potpuno određene upravo prirodom zadatka. Konačno, te se metakognitivne aktivnosti razlikuju i po razini automatiziranosti s kojom ih učenici primjenjuju na zadatku; dok je pomicanje gore-dolje u prozoru programa često automatizirana radnja koja može, ali i ne mora, biti popraćena izjavama o potrebi pregledavanja rezultata već provedenih eksperimenata, informacije o planiranju rada na zadatku su prisutne u verbalnim protokolima učenika, što govori o tome da je ta aktivnost znatno osviještenija, reflektivnija i više intencionalna (posebice onda kad učenici napreduju do razine općeg plana).

Neki autori postavljaju pitanje o tome koliko je korištenje funkcija u nekom računalnom programu uopće izraz metakognitivnih ili samoregulacijskih aktivnosti (Nolen, 2006). Problem je indirektno mjerenje metakognitivnih vještina, odnosno činjenica da se o metakognitivnim aktivnostima zaključuje na temelju drugih aktivnosti. Korištenje funkcija FILE programa nije samo po sebi metakognitivna aktivnost, ali odluka o korištenju pojedine funkcije kako bi se usporedili rezultati određenih eksperimenata sugerira postojanje metakognicije. Stoga je pri određivanju prirode određene aktivnosti, ključno razumjeti motive korištenja pojedinih funkcija. Uz praćenje tragova koje učenici ostavljaju radom na zadatku (u računalnom automatskom zapisniku), potrebno je osigurati podatke o značenju zabilježenih aktivnosti za učenike putem opažanja njihovog rada i praćenja iskaza koje daju tijekom rada.

Vjerojatno je da neki izbori koje učenici rade u računalnom programu nisu svjesni, već su potaknuti znakovima u okruženju zadatka. Npr. korištenje opcije 'selekcija' u programu ne mora biti namjerna radnja, a čak i ako je, ne mora biti pokazatelj samoregulacije. Kad učenik ugleda polje za tu opciju, on može na njega kliknuti bez svjesne odluke o potrebi

organiziranja materijala. Zbog mogućnosti da učenici pri radu isprobavaju različite opcije programa bez stvarne namjere učenja, postoji opasnost da se rad na zadatku istraživačkog učenja pretvori u tzv. 'gaming' sustava (van Joolingen i sur., 2007), koji označava pojavu da učenici kroz zadatak u računalnom okruženju prolaze uz minimum napora, brzim i nepromišljenim reagiranjem ('klikanjem'), ili korištenjem funkcija programa sa svrhom isprobavanja djelovanja sustava, a ne učenja. Doista je primijećeno da neki učenici u nekim trenucima imaju takvu tendenciju isprobavanja pojedinih funkcija programa, ali se takvo korištenje FILE-ovih programskih funkcija nije brojalo kao izraz metakognitivne aktivnosti.

Bez obzira na to koriste li učenici tijekom rada na zadatku programske funkcije FILE-a svjesno i u namjeri samoreguliranja vlastitog procesa učenja ili ne, te funkcije predstavljaju potporne alate koji mogu značajno olakšati rad u FILE-u i kauzalno zaključivanje o odnosima između varijabli. Pokazuje se, međutim, da učenici te mogućnosti rijetko koriste. Učenici ne iskorištavaju prednosti koje im pruža selekcija i organizacija eksperimenata, nego se radije oslanjaju na vlastito pamćenje i očekivanja. Druga istraživanja (Wilhelm i sur., 2005) također otkrivaju rijetko korištenje pomoćnih funkcija FILE-a od strane učenika osnovnoškolske dobi (u šestom razredu) - dok su vraćanje na prethodne eksperimente djeca koristila u prosjeku dvaput tijekom rada na zadatku, selekciju eksperimenata uopće nisu upotrebljavala.

Istraživanja na drugim računalnim programima također potvrđuju da učenici ne koriste dostupne potporne alate u računalnom okruženju, te da ne uspijevaju u potpunosti iskoristiti mogućnosti koje im pruža to okruženje, čak i kad razumiju da im različiti potporni alati mogu pomoći u samoregulaciji učenja (Winters i sur., 2008). Malo korištenje potpornih funkcija pri radu na zadatku sugerira da učenici imaju problema u istraživačkom učenju u računalnom okruženju, te da ono treba dodatnu potporu (Azevedo i Hadwin, 2005; de Jong, 2005; Azevedo, 2007; van Joolingen i sur., 2007; Schraw, 2007). U računalne programe potrebno je ugraditi kognitivne i metakognitivne alate koji, primjerice, od učenika zahtijevaju da postave ciljeve učenja, aktiviraju prijašnja znanja, planiraju i organiziraju učenje, odabiru istraživački pristup na promišljen način, prate rezultate eksperimenata, procjenjuju učenje i vrednuju rezultate rada i slično.

Usprkos malom korištenju potpornih funkcija FILE programa, istraživanje pokazuje da je njihovo korištenje povezano s pozitivnim rezultatima istraživačkog učenja. Također je utvrđeno da planiranje rada na zadatku vodi prikladnijem (sustavnijem) istraživačkom

pristupu i boljem učinku. Ti rezultati koji govore o povezanosti metakognitivnih vještina planiranja i praćenja rada s učinkom na zadatku potvrđuju da je korištenje metakognitivnih vještina važna determinantna uspješnog istraživačkog učenja. Iako korištene statističke analize ne omogućuju utvrđivanje uzročno-posljedičnih veza, može se pretpostaviti da je smjer utjecaja takav da metakognicija određuju pristup koji učenici koriste pri eksperimentiranju, a da to utječe na ostvarene rezultate učenja. Učenicima u istraživačkom učenju izrazito pomaže strukturiranje procesa učenja na način da se eksperimenti provode planski i sustavno i da se njihova provedba aktivno nadgleda i prilagođava ovisno o postignutim rezultatima i o uočenim nedostacima u korištenim istraživačkim pristupima.

Rezultati ovog istraživanja ne odstupaju po nalazu o povezanosti metakognitivnih vještina i istraživačkog učenja od drugih istraživanja, koja također utvrđuju važnu ulogu metakognicije u ostvarivanju uspjeha na takvim zadacima. Schauble (1996) je pokazala razlike u valjanosti zaključivanja kod učenika koji koriste različitu vrstu plana rada. Postojanje više razine plana rada je smatrala izraz opće sustavnosti rada na zadatku, za razliku od lokalne sustavnosti koju je mjerila pomoću korištenja strategije kontrole varijabli. Veenman i Spaans (2005) su utvrdili visoku korelaciju ( $r=,74$ ) između pokazatelja metakognitivnih vještina (na temelju praćenja tragova iz računalnog automatskog zapisnika) i učinka na zadatku istraživačkog učenja u FILE-u. Veenman i suradnici (2004) su dobili nešto nižu, ali i dalje relativno visoku pozitivnu povezanost učestalosti pomicanja gore-dolje u prozoru FILE-a i korištenja strategije «variraj jedan čimbenik u jednom trenutku» sa stečenim znanjem o odnosima između nezavisnih i zavisne varijable u modelu zadatka. Već spomenuta istraživanja Veenmana i suradnika (Veenman i sur., 2002, 2004; Veenman i Spaans, 2005) su, dakle, pokazala da je korištenje metakognitivnih vještina važan prediktor učinka na istraživačkom zadatku, kao i to da te vještine doprinose početnim rezultatima učenja čak i više od inteligencije. Utvrđeno je da se u početnom istraživačkom učenju, u situaciji rješavanja relativno složenog i nepoznatog istraživačkog zadatka, učenici izrazito oslanjaju na vlastite metakognitivne vještine, budući da ih složenost i nepoznatost zadatka ili područja koje se istražuje navodi na heurističko djelovanje (Veenman i sur., 2002). Metakognitivne vještine su važne, dok god je zadatak dovoljno složen da se rješavanje problema ne odvija automatizirano (Prins i sur., 2006). Rezultati ovog istraživanja, koji ukazuju na povezanost metakognitivnih aktivnosti planiranja i istraživačkog učenja u zadnjem (četvrtom) mjerenju, sugeriraju, pak, važnost metakognitivnih vještina kroz cijelo trajanje rada na zadatku.

#### **5.4. Stjecanje metakognitivnog znanja o cilju i strategijama rada na zadatku i povezanost s istraživačkim vještinama i strategijama i učinkom na zadatku**

U istraživanju su ispitana dva elementa metakognitivnog znanja – metakognitivno razumijevanje cilja zadatka istraživačkog učenja i poznavanje strategija potrebnih za njegovo rješavanje. Provjereno je koliko učenici razumiju da je cilj zadatka analizirati učinke pojedinih nezavisnih varijabli, te koliko shvaćaju da je za uspješan rad na zadatku potrebno strateški djelovati i eksperimente provoditi na način koji omogućuje njihovu valjanu usporedbu i zaključivanje.

Na početku prikaza rezultata o metakognitivnom znanju, bit će predstavljeni podaci o postignutim razinama metakognitivnog znanja o cilju zadatka i metastrateškom znanju prije i poslije rada na zadatku. Nakon opisa napredovanja učenika u metakognitivnom znanju nakon sudjelovanja u četiri situacije istraživačkog učenja, metakognitivno znanje će biti povezano s istraživačkim vještinama i strategijama učenika (s korištenjem strategije kontrole varijabli i valjanosti zaključivanja) i sa stjecanjem znanja o kauzalnoj strukturi modela zadatka.

##### ***5.4.1. Promjene u metakognitivnom znanju o cilju i strategijama rada na zadatku***

###### *Direktna procjena metakognitivnog znanja*

Prije analize prikupljenih podataka, potrebno je podsjetiti se da su učenici prvi upitnik metakognitivnog znanja ispunjavali prije rada na zadatku o uništenju šuma, nakon što su u grupnoj situaciji upoznati s programom FILE na primjeru zadatka o dječaku Petru koji kasni u školu<sup>51</sup>. Taj je zadatak onda i korišten kao osnova za procjenu metakognitivnog znanja učenika. Smatrano je da je prikaz zadatka o Petru dovoljan za informiranje učenika o zahtjevima zadatka istraživačkog učenja, kao i aktiviranje učeničkih konceptija o cilju tog zadatka i strategijama koje su prikladne za njegovo rješavanje.

Tablica 27 pokazuje razine metakognitivnog znanja o cilju i strategijama rada na zadatku koje učenici iskazuju prije rada na zadatku.

---

<sup>51</sup> Zadatak o Petru koji kasni u školu je korišten za upoznavanje učenika s programom FILE umjesto glavnog zadatka o uništenju šuma, kako bi se smanjila mogućnost utjecaja te situacije na individualni rad učenika na zadatku o uništenju šuma.

Utvrđeno je da učenici pokazuju vrlo nisku razinu razumijevanja cilja zadatka, kao i razumijevanja prikladnih strategija za njegovo rješavanje, u situaciji kad još nisu pristupili radu na zadatku. Većina se učenika nalazi na razini «0» ili «1», usprkos činjenici da im je zadatak detaljno predstavljen, kao i da im je objašnjeno da na zadatku „*želimo vidjeti koliko minuta Petar kasni u školu ovisno o tome što je toga dana odabrao od navedenih stvari*“, odnosno da se „*nakon rada na zadatku ispituje učenika o tome što je zaključio o tome kakav je odnos navedenih čimbenika i minuta kašnjenja u školu. Pita ga se što ima, a što nema utjecaj na to koliko Petar kasni u školu*“. Potrebno je, međutim, reći da se pri predstavljanju programa FILE i zadatka vodilo računa da se eksplicitno ne govori o cilju zadatka i strategijama njegovog rješavanja. Iako je postupak rada u programu FILE detaljno opisan, u davanju primjera provođenja eksperimenata učenicima nije prikazano valjano eksperimentiranje, niti im je objašnjen princip po kojem treba birati čimbenike.

Tablica 27

Broj učenika s određenom razinom metakognitivnog znanja o cilju i strategijama rada na zadatku prije rada na zadatku o uništenju šuma

Metakognitivno znanje o cilju zadatka	Metastrateško znanje		Ukupno
	Razina 0 (Bez znanja o strategijama)	Razina 1 (Pozitivan ishod)	
Razina 0 (Bez uvida u cilj zadatka)	3	1	4
Razina 1 (Postizanje pozitivnog ishoda)	11	7	18
Razina 2 (Analiza na razini slučaja)	2	1	3
Razina 3 (Analiza na razini čimbenika, ali bez njihovog izdvajanja)	4	5	9
<i>Ukupno</i>	<i>20</i>	<i>14</i>	<i>34</i>

Podaci iz tablice 27 o postignutoj razini metakognitivnog znanja o cilju zadatka prije rada na glavnom zadatku pokazuju da većina ispitanika (53%) ciljem zadatka smatra postizanje pozitivnog ishoda. Tipičan primjer odgovora učenika je «*želi se pomoći dječaku Petru da što brže stigne u školu*». Ipak, znatan se dio ispitanika (26%) već u prvom mjerenju smješta na razinu «3», koju karakterizira namjera istraživanja utjecaja različitih situacija (kombinacija čimbenika) na Petrovo kašnjenje. Na toj razini učenici prepoznaju da je cilj otkriti koji čimbenici imaju utjecaja, ali o njima govore općenito, bez zasebnog izdvajanja i bez osvrtnja na pojedine čimbenike. Tipičan odgovor na ovoj razini bio je sljedeći: «*Cilj je razotkriti razloge Petrovog kašnjenja u školu*». Ta razina «3» ujedno predstavlja najvišu razinu koju učenici postižu u metakognitivnom razumijevanju cilja zadatka prije rada na zadatku o uništenju šuma. Više razine, koje se odnose na usmjerenost učenika na analizu učinka (pojedinih) čimbenika, ne ostvaruje niti jedan ispitanik.

Postignute razine metastrateškog znanja prije rada na glavnom zadatku još su niže. Niti jedan ispitanik ne nalazi se iznad razine «1». Većina ispitanika (59%) ne pokazuje svijest o potrebi korištenja neke strategije, niti znanje o strategijama koje bi mogle biti prikladne za uspješno rješavanje prikazanog zadatka istraživačkog učenja. Tipični odgovori učenika na razini «0» bili su: «*Sličice odredim po slučaju*» ili «*Kliknem mišem na sličicu*», a na razini «1»: «*Sličice biram prema tome koliko su te stvari jednostavnije ili brže za Petra*» ili «*Ako tražim najbrži način, ja ću odabrati sličice za koje mislim da će omogućiti da on brže stigne*».

Uspoređujući postignute razine dviju sastavnica metakognitivnog znanja kod istih učenika, utvrđeno je da čak 23 učenika (68%) postiže bolje metakognitivno razumijevanja cilja, nego razumijevanje strategija potrebnih za uspješno rješavanje zadatka, dok su razine (0-0 ili 1-1) međusobno usklađene kod 10 učenika (29%). Čak i učenici koji ciljem zadatka vide ostvarivanje pozitivnih ishoda (razina «1»), često ne daju prijedloge strategija takve vrste, već se zadržavaju na opisu postupka ili odgovorima tipa «*kako god želiš*» (razina «0»). Nepostojanje bilo kakve refleksije o potrebi korištenja strategija za dolaženje do cilja iskazuje i polovina učenika koji postižu razinu «2» ili «3» u metakognitivnom znanju o cilju zadatka, dok se druga polovina odlučuje za pristup biranja čimbenika prema principu ostvarivanja pozitivnog ishoda.

Nalaz o višoj razini metakognitivnog znanja o cilju zadatka nego o potrebnim strategijama za ostvarivanje postavljenog cilja može značiti da je učenicima lakše doprijeti do uvida o tome što se želi ostvariti zadatkom istraživačkog učenja, nego osmisliti to kako postići takav cilj. Takav se nalaz čini logičnim, imajući na umu mogućnost da se isti cilj može postići pomoću različitih strategija. S druge strane, može se pretpostaviti da je dobiveni nalaz o višoj razini metakognitivnog znanja kad se radi o cilju zadatka povezan s mogućnošću da je u prikazu programa FILE i zadatka o dječaku Petru koji kasni u školu učenicima dano više znakova koji govore o cilju, nego o načinu rješavanja zadatka.

U nastavku je analizirano koliko su učenici napredovali u metakognitivnom znanju nakon četiri situacije rada na zadatku o uništenju šuma. Prvo je opisan napredak u metakognitivnom znanju o cilju zadatka, a zatim i napredak u metastrateškom znanju.

U tablici 28 dat je usporedni prikaz postignutih razina metakognitivnog znanja o cilju zadatka prije i poslije rada na zadatku.

Iz tablice 28 je vidljivo da dolazi do značajnog pomaka prema višim razinama metakognitivnog znanja o cilju zadatka, što potvrđuju i rezultati testiranja statističke značajnosti učinka 'prije – poslije' ( $T=16,89$ ,  $z=-4,39$ ,  $p<,001$ ,  $r=,53$ ).

Dok se nakon rada na zadatku na najnižim razinama metakognitivnog znanja o cilju zadatka (razinama «0» do «2») zadržava samo troje ispitanika, najveći dio učenika (79%) se smješta na razinu «3» i razinu «4». To su razine na kojima učenici prepoznaju da je cilj zadatka utvrditi što (koji čimbenici) dovodi do određenih rezultata eksperimenata, ali se konceptualno ne usmjeravaju na potrebu analize i utvrđivanja učinka svakog pojedinog čimbenika. Najvišu razinu (razinu «5»), upravo onu koju karakterizira usmjerenost na analizu na razini pojedinih čimbenika, postiže na kraju istraživanja samo četiri učenika (11%).

Tablica 28

Postignute razine metakognitivnog znanja o cilju zadatka prije i poslije rada na zadatku istraživačkog učenja: broj učenika na pojedinoj razini

	Prije rada na zadatku	Poslije rada na zadatku
	<i>n</i>	<i>n</i>
Razina 0 (Bez uvida u cilj zadatka)	4	1
Razina 1 (Postizanje pozitivnog ishoda)	18	1
Razina 2 (Analiza na razini slučaja)	3	1
Razina 3 (Analiza na razini čimbenika, ali bez njihovog izdvajanja)	9	13
Razina 4 (Analiza na razini čimbenika koja uključuje više čimbenika)	0	14
Razina 5 (Analiza na razini čimbenika, uz usmjerenost na pojedini čimbenik)	0	4

Analiza promjena u razini metakognitivnog znanja o cilju zadatka na individualnoj razini (prikazana u tablici 15 u Prilogu) pokazuje da do napredovanja u razumijevanju cilja zadatka istraživačkog učenja dolazi kod gotovo svih ispitanika (31 ili 91%). Prosječno se napreduje za dvije razine, iako su prisutna i veća napredovanja, ona od tri ili četiri stupnja. Učenici koji su prije rada na zadatku bili na razini «0» pomiču se prema razinama «2» do «4», a učenici koji su bili na razini «1» pokazuju sličan pomak prema razinama «3» do «5», iako se najveći dio tih ispitanika zadržava na razinama «3» i «4».

Tek se kod dvoje učenika javlja nazadovanje, a kod jednog stagnacija u razvoju metakognitivnog razumijevanja cilja zadatka. To je vjerojatno povezano s činjenicom da se radi o učenicima koji su se kod prve primjene metakognitivnog upitnika nalazili na (tada)



najvišoj postignutoj razini (razini «3»). Može se pretpostaviti da za te učenike situacija istraživačkog učenja ponuđena u istraživanju bila nedovoljna za poticanje daljnjeg razvoja metakognitivnog razumijevanja.

Tablica 29 prikazuje postignute razine metastrateškog znanja prije i poslije rada na zadatku.

Utvrđeno je da i u metastrateškom znanju dolazi do značajnog napredovanja uslijed rada na zadatku istraživačkog učenja ( $T=4,05$ ,  $z=-3,54$ ,  $p<,001$ ;  $r=,43$ ).

*Tablica 29*

Postignute razine metastrateškog znanja prije i poslije rada na zadatku istraživačkog učenja: broj učenika na pojedinoj razini

	Prije rada na zadatku	Poslije rada na zadatku
	<i>n</i>	<i>n</i>
Razina 0 (Bez znanja o strategijama)	20	16
Razina 1 (Odabir sličica koje doprinose pozitivnom ishodu)	14	0
Razina 2 (Odabir različitih kombinacija i opažanje rezultata)	0	6
Razina 4 (Usporedba slučajeva u kojima se razlikuje više čimbenika)	0	0
Razina 5 (Usporedba slučajeva u kojima je samo jedan čimbenik promijenjen)	0	6
Razina 6 (Usporedba slučajeva u kojima je samo jedan čimbenik promijenjen, a ostali su nepromijenjeni)	0	6

Značajan udio učenika (12 ili 35%) smješta se nakon rada na zadatku na najviše razine metastrateškog znanja, koje karakterizira razumijevanje potrebe uspoređivanja eksperimenata provedenih na kontroliran način, variranjem jednog čimbenika u jednom trenutku (u svrhu utvrđivanja učinka tog čimbenika). Zanimljivo je napomenuti da analiza individualnih napredovanja učenika u metastrateškom znanju (prikazana u tablici 16 u Prilogu) pokazuje da te najviše razine podjednako ostvaruju i učenici koji su istraživanje započeli na razini «0» i oni na razini «1».

Međutim, i nakon rada na zadatku o uništenju šuma, prisutan je velik broj ispitanika (16, što je gotovo 50%) koji iskazuju najnižu razinu metastrateškog znanja (i koji, dakle, nisu napredovali u metastrateškom znanju). Pokazuje se da su to najvećim dijelom učenici koji su i u prvom mjerenju pripadali nultoj razini metastrateškog razumijevanja, iako ima i učenika koji su na početku istraživanja kategorizirani na razinu «1».

U tablici 30 su uspoređene razine metakognitivnog znanja o cilju i strategijama rada na zadatku koje su postignute kod istih učenika nakon rada na zadatku.

Pokazuje se da i dalje većina učenika (20 ili 59%) postiže višu razinu metakognitivnog znanja u području razumijevanja cilja zadatka, nego u području razumijevanja strategija nužnim za njegovo rješavanje, iako je (u odnosu na prvo mjerenje) povećan broj učenika koji višu razinu postižu u metastrateškom znanju, u odnosu na metakognitivno znanje o cilju zadatka (12 ili 35%). Nakon rada na zadatku, prisutan je tako tek mali broj učenika s komparabilnom razvijenošću obje sastavnice metakognitivnog znanja. Samo dvoje učenika ostvaruje visok rezultat u obje sastavnice i kombinacije razina 5 – 5 i 5 - 6.

*Tablica 30*

Broj učenika s određenom razinom metakognitivnog znanja o cilju i strategijama rada na zadatku poslije rada na zadatku o uništenju šuma

		Metastrateško znanje						Ukupno <i>n</i>
		Razina 0 <i>n</i>	Razina 1 <i>n</i>	Razina 2 <i>n</i>	Razina 4 <i>n</i>	Razina 5 <i>n</i>	Razina 6 <i>n</i>	
Metakognitivno znanje o cilju zadatka	Razina 0	0	0	1	0	0	0	1
	Razina 1	0	0	1	0	0	0	1
	Razina 2	1	0	0	0	0	0	1
	Razina 3	7	0	3	0	1	2	13
	Razina 4	6	0	1	0	4	3	14
	Razina 5	2	0	0	0	1	1	4
	<i>Ukupno</i>	16	0	6	0	6	6	34

U slučajevima u kojima je metakognitivno razumijevanje cilja zadatka na višoj razini od metastrateškog znanja, uvijek se radilo o učenicima koji se po metastrateškom znanju nalaze na niskim razinama (na razinama «0» (nema strategije) ili «2» (probati različite kombinacije i opažati rezultate)). S druge strane, u slučajevima u kojima je metastrateško razumijevanje bolje razvijeno od metakognitivnog znanja o cilju zadatka, razlike u razinama nisu toliko velike, i većinom se odnose na gornji dio ljestvice razina. Naime, učenici koji ostvaruju najviše razine u metastrateškoj sastavnici, nalaze se po metakognitivnom znanju o cilju zadatka uglavnom na razini «4» (razini koja znači da učenici razumiju da je cilj ispitati koji od čimbenika imaju utjecaj na uništenje šuma, ali se u odgovoru ne osvrću na potrebu ispitivanja učinka jednog čimbenika u jednom trenutku).

### *Primjena metakognitivnog znanja u transfernom zadatku*

Dosad predstavljeni rezultati o postignutim razinama metakognitivnog znanja prije i poslije rada na zadatku istraživačkog učenja temeljili su se na otvorenim odgovorima učenika na direktna pitanja o cilju i strategijama rada na zadatku. No, osim procjene razvijenosti metakognitivnog znanja učenika putem tih pitanja, metakognitivno znanje je u ovome radu ispitano i putem zadatka koji od učenika traži primjenu metakognitivnog znanja, što predstavlja višu razinu znanja u različitim taksonomijama znanja, npr. po revidiranoj Bloomovoj taksonomiji (Anderson i Krathwohl, 2001). Učenicima je predstavljena situacija u kojoj dvoje prijatelja iz razreda (nazvani Matija i Nika) rade na zadatku o Petru koji kasni u školu, i nakon što su napravili prvi eksperiment, imaju različite ideje o tome kako provesti drugi eksperiment. Jedan učenik bira valjanu strategiju kontrole varijabli tj. strategiju «variraj jednu varijablu u jednom trenutku», a drugi bira nevaljanu strategiju «drži jednu varijablu konstantnom u jednom trenutku». Od ispitanika se tražilo da odrede koji prijedlog provedbe drugog eksperimenta smatraju boljim (vidi tablicu 31), te da objasne svoj odgovor. U tim odgovorima učenici trebaju iskazati da razumiju zašto je plan bolji (metastrateško razumijevanje), te objasniti što se može saznati slijeđenjem tog plana (metakognitivno razumijevanje cilja zadatka).

Prije rada na zadatku istraživačkog učenja, prijedlog koji uključuje valjano eksperimentiranje bira 11 učenika (32%), dok drugi prijedlog bira tek nešto manje učenika (9 ili 26%). Učenička objašnjenja odabranih odgovora, međutim, otkrivaju da tek dvoje učenika bira prijedlog valjanog eksperimentiranja uz razumijevanje korištenja kontrole varijabli i shvaćanje jedinstvene mogućnosti utvrđivanja utjecaja variranog čimbenika na Petrovo kašnjenje u takvom prijedlogu. Ostali učenici argumentiraju svoj odabir time što, po njihovim očekivanjima, preferirani prijedlog drugog eksperimenta predstavlja povoljniju kombinaciju čimbenika, onu uz koju se može očekivati manje Petrovo kašnjenje. Istu argumentaciju koriste učenici koji biraju suprotni prijedlog (onaj koji predstavlja korištenje nevaljane strategije eksperimentiranja), kao i učenici koji odabiru odgovor 'niti jedan prijedlog nije dobar'.

Dakle, prije rada na zadatku istraživačkog učenja, tek dvoje učenika bira pravilan plan eksperimentiranja i zna objasniti zašto je on bolji, čime pokazuju razvijenost metastrateškog razumijevanja. Uz ispravnu argumentaciju odabira kvalitetnijeg prijedloga eksperimentiranja, to dvoje ispitanika pokazuje i metakognitivno razumijevanje cilja zadatka jer ispravno zaključuju o tome što se odabirom različitih prijedloga može saznati.

Ispravno identificiraju da se slijeđenjem nekontrolirane usporedbe (korištenjem prijedloga nevaljanog eksperimentiranja) ne može ništa valjano zaključiti, odnosno da se u kontroliranoj usporedbi može zaključiti ima li promijenjeni čimbenik utjecaj na Petrovo kašnjenje ili ne.

Svi ostali ispitanici ne uspijevaju se odmaknuti od usmjerenosti na rezultate eksperimenata (iako im zapravo rezultati do kojih dovode kombinacije čimbenika u prijedlozima drugom eksperimenta uopće nije prikazani!), pa na odgovore o tome što su mogli saznati slijedeći prijedlog jednog ili drugog učenika, uglavnom odgovaraju «*Saznali bismo da će (manje/više) zakasniti*», «*Brže bi došao da su odabrani neki drugi čimbenici*» ili «*Saznali bi da ga nešto od ovog ubrzava/ usporava*».

Ovakvi nalazi koji govore o tome da učenici preferiraju prijedloge provedbe eksperimenata na temelju toga koliko prema njihovim teorijskim očekivanjima predložena kombinacija čimbenika dovodi do pozitivnog rezultata eksperimenata, potvrda su nalaza o razvijenosti metakognitivnog znanja o cilju zadatka i strategijama rada dobivenih direktnim pitanjima. S obzirom da su učenici prije rada na zadatku istraživačkog učenja uglavnom kategorizirani na razine «0» ili «1» u obje sastavnice metakognitivnog razumijevanja, logično je da koriste ista objašnjenja za vlastite odabire u zadatku koji od njih traži primjenu metakognitivnih znanja.

Međutim, činjenica o postojanju dvoje učenika koji su u zadatku koji zahtijeva primjenu metakognitivnog znanja pokazali potpunu kompetentnost u ovom području, a u odgovoru na direktna pitanja o cilju i strategijama rada na zadatku istraživačkog učenja bili kategorizirani na razinama 1-1 i 1-0, govori o mogućnosti da procjena metakognitivnog znanja putem davanja otvorenih pismenih odgovora na direktna pitanja o cilju i strategijama rada na zadatku istraživačkog učenja može podcijeniti stvarnu razinu metakognitivnog znanja.

Nakon rada na zadatku ponovno je za procjenu proceduralnog metakognitivnog znanja primijenjen isti zadatak o Petru koji kasni u školu. Procjena metakognitivnog znanja korištenjem ovog zadatka (a ne glavnog zadatka o uništenju šuma) može se tretirati kao transferni zadatak, budući da se procjena temelji na sadržajnom području različitom od onog u kojem su učenici «vježbali» istraživačko učenje. Ovaj zadatak stoga predstavlja rigorozniju mjeru metakognitivnog razumijevanja, od one koja bi uključivala sadržaj na kojem su učenici eksperimentirali tijekom rada na zadatku.

U tablici 31 prikazan je broj učenika koji su birali određeni prijedlog provedbe drugog eksperimenta u prvoj i drugoj primjeni metakognitivnog upitnika.

*Tablica 31*

Broj učenika koji biraju određeni prijedlog eksperimentiranja u zadatku o Petru koji kasni u školu prije i poslije rada na zadatku istraživačkog učenja

	Prije rada na zadatku	Poslije rada na zadatku
Prihvata prijedlog valjanog eksperimentiranja	11	11
Prihvata prijedlog nevaljanog eksperimentiranja	9	7
Oba prijedloga su podjednako dobra	2	10
Niti jedan prijedlog nije dobar	10	5
Ne zna	2	1

Kao i prije rada na zadatku, nakon četiri situacije istraživačkog učenja, tek 11 učenika (32%) bira prijedlog valjanog eksperimentiranja. Od toga broja, samo tri ispitanika svoj odabir argumentiraju upravo korištenjem strategije kontrole varijable u izabranom prijedlogu. Tih tri ispitanika, nadalje, ispravno prepoznaju da se u kontroliranoj usporedbi može zaključivati o učinku jedinog promijenjenog čimbenika na rezultat eksperimenta, odnosno da se u nekontroliranoj usporedbi takav zaključak ne može valjano donijeti. To su, dakle, ispitanici koji imaju razvijeno metakognitivno znanje o cilju zadatka i strategijama rada na najvišoj razini.

Ostali ispitanici (8 od 11), koji smatraju prijedlog valjanog eksperimentiranja boljim, uopće ne uočavaju činjenicu da on jedini omogućuje donošenje valjanog zaključka o učinku određenog čimbenika, već odabir toga prijedloga argumentiraju „boljom“ kombinacijom čimbenika, onom koja je, prema njihovim očekivanjima, povoljnija za postizanje cilja točnog dolaska Petra u školu. Odabir suprotnog prijedloga koji čini sedam učenika (21%), argumentira se potpuno jednako - kao prijedlog koji predstavlja slučaj u kojem će Petar brže stići u školu.

Konceptualno istovjetno objašnjenje daju i učenici koji smatraju da su oba prijedloga jednako dobra, kao i učenici koji smatraju da niti jedan prijedlog nije dobar. Ti učenici dominantno navode da obje kombinacije čimbenika dovode do sličnih rezultata, odnosno smatraju da bi neka druga kombinacija čimbenika (opet prema njihovim teorijama) dala povoljniji rezultat.

Navedeni rezultati učenika na ovom zadatku pokazuju da, nakon rada na zadatku istraživačkog učenja o uništenju šuma, tek troje ispitanika, barem prema ovim mjerama,

ima dostatno razvijeno proceduralno metakognitivno znanje o cilju zadatka i strategijama za njegovo rješavanje, koje može primijeniti u novim situacijama, dok se svi ostali učenici nalaze na niskoj razini – razini za koju je tipična usmjerenost na postizanju pozitivnih ishoda u eksperimentiranju. Takvi su nalazi u značajnom raskoraku s rezultatima o napretku u metakognitivnom znanju o cilju i strategijama rada na zadatku koji su dobiveni u slučaju kad se metakognitivno znanje procjenjuje direktnim pitanjima. Činjenica da se metakognitivno znanje stečeno kroz rad na zadatku o uništenju šuma ne uspijeva primijeniti u kontekstu (po formi paralelnog) transfernog zadatka koji koristi isti model odnosa između varijabli samo na drugom sadržaju, sugerira da su metakognitivni dobitci rada na zadatku istraživačkog učenja nedovoljni, suviše ograničeni i vezani samo za neposrednu situaciju učenja. Nalazi o razvijenosti dvaju sastavnica metakognitivnog znanja kod pojedinih učenika sugeriraju da glavni problem predstavljaju manjkavosti u metastrateškom znanju, koje onemogućuju učenicima prepoznavanje i argumentiranje valjanog pristupa eksperimentiranju.

Posebnu poteškoću u transferu vjerojatno predstavlja činjenica da je korišteni transferni zadatak iz područja svakodnevnog života, koje se, kao i (slično) socijalno područje, u istraživanjima pokazuje posebno problematičnim za uspostavu valjanih obrazaca eksperimentiranja i zaključivanja, uglavnom zbog otežane koordinacije eksperimentalnih nalaza s izrazito bogatim, elaboriranim i otpornim teorijama učenika (Kuhn i sur., 1995). Pretpostavlja se da zadatak o Petrovom kašnjenju u školu budi kod ispitanika brojne asocijacije na vlastito školsko iskustvo, što može ometati učenike u sagledavanju zadatka kao istraživačkog zadatka, i usmjeriti ih na zauzimanje pristupa u kojem je cilj rješavanje problema kašnjenja (pronalaženje optimalne kombinacije čimbenika), a ne analiza učinaka pojedinih čimbenika.

#### ***5.4.2. Odnos metakognitivnog znanja učenika i istraživačkih vještina***

U nastavku je ispitano razlikuju li se učenici koji postižu različite razine metakognitivnog znanja u tome koliko su uspješno provodili eksperimentiranje i zaključivanje na zadatku koji je od njih zahtijevao primjenu analitičkog pristupa i sustavno variranje čimbenika. Za potrebe ove analize, umjesto zasebnih mjera metakognitivnog znanja o cilju zadatka i metastrateškog znanja, derivirana je nova mjera prema principu postignute više razine u bilo kojoj od dvaju sastavnica metakognitivnog znanja. Mogući raspon nove mjere iznosio

je između 0 (za učenike koji u obje sastavnice postižu najnižu razinu metakognitivnog znanja) i 6 (za učenike koji postižu razinu «6» u području metastrateškog znanja)<sup>52</sup>.

Takvu zajedničku mjeru metakognitivnog znanja predložile su Kuhn i Pearsall (1998), imajući u vidu činjenicu da mjere metakognitivnog znanja koje se koriste u istraživanjima, a koje se temelje na verbalnim iskazima, mogu podcijeniti stvarnu razinu metakognitivnog razumijevanja koju učenici imaju. Budući da je logično pretpostaviti da ispitivanje metakognitivnog znanja putem pismenog iskaza kakav je korišten u ovom istraživanju, također podcjenjuje pravu vrijednost metakognitivnog znanja učenika (zbog posredovanosti jezičnih vještina i formata odgovaranja koji ostavlja učenicima potpunu slobodu u odlučivanju o tome kako odgovoriti), čini se također opravdanim za ispitivanje povezanosti metakognitivnog znanja i strateške izvedbe na zadatku koristiti podatak o višoj ostvarenoj razini metakognitivnog znanja.

#### *Metakognitivno znanje i istraživačko učenje u prvom mjerenju*

Prema novoj mjeri metakognitivnog znanja, u situaciji prije rada na zadatku o uništenju šuma, učenici ostvaruju metakognitivne razine od «0» do «3». Kod svih učenika, osim kod jednog, ta je razina metakognitivnog znanja postignuta na temelju bolje procijenjenog metakognitivnog znanja o cilju zadatka.

Provjereno je razlikuju li se učenici koji prije početka rada na zadatku ostvaruju različite razine metakognitivnog znanja u stečenom znanju o kauzalnoj strukturi modela zadatka i u kvaliteti njihove strateške izvedbe u prvom mjerenju. Dvije su korištene mjere, pokazatelji kvalitete strateške izvedbe. Jedna je mjera «prosječan broj čimbenika mijenjan po eksperimentu», koja je pokazatelj korištenja strategije kontrole varijabli i izraz sustavnog eksperimentiranja. Druga je mjera valjanost jednostavnih zaključaka. Iako su ove mjere visoko povezane, budući da je za valjano zaključivanje nužan preduvjet kontrolirana usporedba eksperimenata u kojima je mijenjan samo jedan čimbenik, one nisu sasvim istovjetne, pa su analize provedene za obje mjere.

---

<sup>52</sup> Razina 6 postoji samo u području metastrateškog znanja, i nema svoj pandan u području metakognitivnog znanja o cilju zadatka. Isto tako, razina 3 je definirana samo unutar područja metakognitivnog znanja o cilju zadatka, a izostaje u području metastrateškog znanja. Kao rezultat toga, u novoj mjeri metakognitivnog znanja, učenici koji postižu razinu «3», to nužno ostvaruju u području metakognitivnog znanja o cilju zadatka, a učenici koji postižu razinu «6» to postižu u području metastrateškog znanja.

U tablici 32 su prikazane centralne vrijednosti korištenih mjera u prvom mjerenju za skupine učenika koje ostvaruju različite razine metakognitivnog znanja prije početka rada na zadatku istraživačkog učenja.

*Tablica 32*

Prosječne vrijednosti (C) prosječnog broja čimbenika mijenjanih po eksperimentu, valjanosti jednostavnih zaključaka i točnosti učeničkih teorija u prvom mjerenju, ovisno o razinama metakognitivnog znanja prije rada na zadatku

	Razina 0	Razina 1	Razina 2	Razina 3
Broj učenika	3	19	3	9
Prosječan broj čimbenika mijenjan po eksperimentu u prvom mjerenju	2,30	2,44	2,56	2,19
Valjanost jednostavnih zaključaka u prvom mjerenju	50,00	44,44	46,67	40,00
Točnost teorija učenika o odnosima između varijabli	7	5	7	6

Testiranje međugrupnih razlika na korištenim mjerama je provedeno spajanjem skupina razine «0» i «1», te skupina «2» i «3», zbog malog broja učenika na pojedinim razinama. Pokazuje se da u prvoj situaciji rada na zadatku istraživačkog učenja nema statistički značajnih razlika između skupina koje su kategorizirane u različite razine metakognitivnog znanja ( $U_{skv}=127,50$ ,  $p=,880$ ,  $r=,03$ ;  $U_{valj}=125,00$ ,  $p=,810$ ,  $r=,04$ ;  $U_{toc}=97,50$ ,  $p=,214$ ,  $r=,22$ ). Nepostojanje razlika u valjanosti eksperimentiranja i zaključivanja, kao i točnosti teorija učenika o odnosima među varijablama na početku rada na zadatku istraživačkog učenja kod učenika koji prije rada na zadatku izražavaju različito metakognitivno znanje može se protumačiti na različite načine. Moguće je da se razlozi nepostojanja povezanosti između viših razina metakognitivnog znanja i uspješnijeg eksperimentiranja i zaključivanja kriju u činjenici općenito prilično niske razine metakognitivnog znanja kod učenika u trenutku kad još nisu pristupili radu u FILE-u. Čak i najviša postignuta razina, razina «3», mogla je biti nedovoljna za značajniji iskorak u strateškom djelovanju, te predstavljati podjednako neprikladan mentalni okvir za započinjanje istraživačkih aktivnosti kao i neka niža razina.

Čini se, međutim, logičnim pretpostaviti da nepostojanje razlika između učenika različitih razina metakognitivnog znanja proizlazi iz toga što su te razine bile odraz (samo) deklarativnog znanja koje se temeljilo na površnom upoznavanju sa sadržajima i postupcima rada na zadatku, a ne na vlastitom iskustvu i refleksiji tog iskustva. Vjerojatno je opravdano tvrditi da se pravo metakognitivno razumijevanje može potaknuti tek radom na zadatku, stvarnim provođenjem eksperimenata i izvođenjem različitih nevaljanih i



valjanih, pogrešnih i točnih zaključaka. Moguće je zamisliti da sudjelovanje u istraživačkim aktivnostima i provođenje prvih eksperimenata na zadatku istraživačkog učenja kod (motiviranijih i sposobnijih) učenika brzo dovodi do jačanja strateškog djelovanja i promjena na meta razini, te da procjena metakognitivnog znanja donesena prije rada na zadatku time postaje irelevantna. Zanimljivo je uočiti da se valjani zaključci u prvom mjerenju pojavljuju na svim razinama metakognitivnog znanja, čak i na onoj najnižoj. Od 22 učenika koji su se nalazili na metakognitivnoj razini «0» ili «1», čak je 10 učenika imalo u prosjeku više od 50% valjanih jednostavnih zaključaka u prvom mjerenju. Podjednaku razinu izvedbe ostvario je jednak udio učenika (pet od 12) koji su se nalazili na razini «2» ili «3».

Nadalje, dio objašnjenja nalaza o nepostojanju razlika između učenika različitih razina metakognitivnog znanja vjerojatno se nalazi u mogućnosti da je procijenjena razina metakognitivnog znanja doista bila podcijenjena, zbog već spominjane jezične posredovanosti te mjere, ali i formata pitanja koji nije omogućavao šire elaboracije i upućivanje potpitanja. O tome zasigurno govore već spomenuti podaci o dvoje ispitanika koji su kategorizirani na razinu «0» ili «1», a koji su u zadatku o Petru u kojem se zahtijevala primjena metakognitivnih znanja pokazali potpuno metakognitivno razumijevanje.

Na kraju, nalazi o nepostojanju razlika u strateškom djelovanju između učenika različitih metakognitivnih razina mogu se povezati s nalazima temeljenima na kvalitativnim opažanja procesa učeničkog rada na zadatku, koji sugeriraju da su učenici (barem dio njih) do prvih valjanih zaključaka dolazili gotovo slučajno, bez jasne namjere ispitivanja pojedinih čimbenika i bez razumijevanja potrebe kontroliranja čimbenika u usporednim eksperimentima, dakle bez postojanja snažne meta razine. Događalo se da su neki učenici prve valjane zaključke donosili u kontekstu provođenja eksperimenata s ciljem generiranja specifičnih ishoda, primjerice, kad su u namjeri utvrđivanja najvišeg stupnja uništenja druge vrste šuma, valjano varirali samo čimbenik 'vrsta drveća u šumi' i, na temelju analize prikupljenih podataka, valjano zaključili o učinku (ili nepostojanju učinka) tog čimbenika. Iako donošenje valjanog zaključka na ovaj način podrazumijeva analitičko vrednovanje prikupljenih nalaza, ono ne podrazumijeva postojanje refleksivnog pristupa ili metastrateške svjesnosti u fazi osmišljavanja i provedbe eksperimenta.

### *Metakognitivno znanje i istraživačko učenje u zadnjem mjerenju*

Provjereno je razlikuju li se učenici različite razine metakognitivnog znanja poslije rada na zadatku istraživačkog učenja po stečenom znanju i po kvaliteti eksperimentiranja i zaključivanja u zadnjem, četvrtom mjerenju.

Prije utvrđivanja razlika između tih skupina, potrebno je primijetiti da se učenici nakon rada na zadatku po zajedničkoj mjeri metakognitivnog znanja raspodjeljuju na razine «2» do «6». Svi učenici se, dakle, pomiču od razina koje karakterizira orijentiranost na ishode eksperimenata na razine koje predstavljaju orijentiranost na uvjete (čimbenike) koji dovode do ishoda.

U tablici 33 prikazane su centralne vrijednosti korištenih mjera u četvrtom mjerenju za skupine učenika koje ostvaruju različite razine metakognitivnog znanja poslije rada na zadatku istraživačkog učenja.

*Tablica 33*

Prosječne vrijednosti (C) prosječnog broja čimbenika mijenjanih po eksperimentu, valjanosti jednostavnih zaključaka i točnosti učeničkih teorija u četvrtom mjerenju, ovisno o razinama metakognitivnog znanja poslije rada na zadatku

	Razina 2	Razina 3	Razina 4	Razina 5	Razina 6
Broj učenika	3	10	7	8	6
Prosječan broj čimbenika mijenjan po eksperimentu u četvrtom mjerenju	2,89	2,11	1,85	1,90	1,68
Valjanost jednostavnih zaključaka u četvrtom mjerenju	33,33	61,12	66,67	77,38	83,34
Točnost teorija učenika o odnosima između varijabli	3	8	10	9,5	8,5

Iz tablice 33 je uočljivo da s porastom razine metakognitivnog znanja raste valjanost eksperimentiranja i zaključivanja – učenici koji ostvaruju najvišu razinu metakognitivnog znanja sustavnije eksperimentiraju i donose više valjanih zaključaka od učenika koji ostvaruju niže razine metakognitivnog znanja. Stečeno znanje o kauzalnoj strukturi modela zadatka u prosjeku je, također, manje kod učenika koji se smještaju na najnižu razinu metakognitivnog znanja, nego kod učenika koji iskazuju više razine.

Zbog malog broja učenika na najnižoj razini, nije bilo moguće provesti testiranje statističke značajnosti razlika između svih skupina. Stoga je ono provedeno na ekstremnim skupinama, tako da su u jednu skupinu spojene razine «2» i «3», a u drugu razine «5» i «6». Među tim dvjema skupinama utvrđene su statistički značajne razlike u korištenju

strategije kontrole varijabli ( $U=40,00$ ,  $p=,013$ ,  $r=,48$ ) i u valjanosti jednostavnog zaključivanja ( $U=48,00$ ,  $p=,036$ ,  $r=,40$ ), dok razlike u točnosti teorija učenika o odnosima između varijabli nisu statistički značajne, ali ukazuju na srednje veliki učinak ( $U=54,00$ ,  $p=,067$ ,  $r=,35$ ).

Frekvencijska analiza rezultata valjanosti jednostavnih zaključaka kod skupina učenika na različitim razinama metakognitivnog znanja (prikazana u tablici 34) također ukazuje na trend bolje strateške izvedbe na višim razinama metakognitivnog znanja.

Može se vidjeti da među učenicima koji se nakon četiri situacije rada na zadatku o uništenju šuma nalaze na najnižoj postignutoj razini metakognitivnog znanja nema onih koji uspijevaju postići više od 50% valjanih zaključaka.

Na višim razinama metakognitivnog znanja pojavljuje se znatno veći udio učenika koji pokazuju uspješno strateško djelovanje, čak i kad se radi o razinama «3» ili «4», na kojima nije prisutan jasan analitički fokus prema utvrđivanju učinka pojedinih čimbenika, kao ni potpuno razumijevanje potrebe usporedbe kontroliranih eksperimenata.

Na razinama «5» i «6» dominantno je valjano zaključivanje, ali ne izostaju sasvim i neprikladni obrasci rada na zadatku. Po jedan ispitanik na tim razinama ne uspijeva u zadnjem mjerenju postići više od 50% valjanih zaključaka, što govori o tome da čak i visoka razina razumijevanja cilja i strategija ne osigurava strateški uspjeh nužno i uvijek.

*Tablica 34*

Broj učenika na pojedinim razinama metakognitivnog znanja s obzirom na 50% kriterij valjanosti jednostavnih zaključaka u četvrtom mjerenju

	manje od 50% valjanih jednostavnih zaključaka u četvrtom mjerenju	više od 50% valjanih jednostavnih zaključaka u četvrtom mjerenju
	<i>n</i>	<i>n</i>
Razina 2	3	0
Razina 3	2	8
Razina 4	2	5
Razina 5	1	7
Razina 6	1	5

Odnos između metakognitivnog znanja i valjanog zaključivanja je ispitan i obrnuto, analizirajući metakognitivnu razinu učenika koji su postigli visok učinak na zadatku, odnosno više od 50% valjanih zaključaka u posljednja dva mjerenja (trećem i četvrtom).

Od tih učenika, kojih ukupno ima 26, svi postižu barem razinu «3» kad se radi o zajedničkoj mjeri metakognitivnog znanja.

Analiza uže skupine učenika koji postižu 75% i više valjanih zaključaka u posljednja dva mjerenja (koju čini 14 učenika) pokazuje da se ti učenici uglavnom nalaze na najvišim razinama metakognitivnog znanja - pet učenika je na razini «5», a pet na razini «6». Podsjetimo da se razina «6» nužno temelji na visokom postignuću u području metastrateškog znanja, dok se razina «5» kod nekih od strateški izuzetno uspješnih učenika pojavljuje na temelju jedne, a kod drugih na temelju druge sastavnice metakognitivnog znanja.

Zanimljivo je ovdje, međutim, istaknuti da čak pet učenika iz skupine (ovih 14) vrlo uspješnih učenika pokazuju metastrateško znanje na najnižoj razini (razini «0»). Čini se da je za visoku stratešku izvedbu tih učenika dovoljan analitički fokus koji im je osiguralo prikladno metakognitivno znanje o cilju zadatka, usprkos nemogućnosti eksplicitne refleksije o strategijama potrebnim za ostvarivanje zadanih ciljeva. O pojavi nesukladnih rezultata na strateškoj i metastrateškoj razini bit će još riječi u okviru kvalitativne analize procesa istraživačkog učenja na slučajevima koji pokazuju napredak u strateškom djelovanju na zadatku o uništenju šuma.

#### ***5.4.3. Metakognitivno znanje o cilju i strategijama rada na zadatku: integracija rezultata i rasprava***

Metakognitivno znanje o cilju i strategijama rada na istraživačkom zadatku izuzetno je važno za područje istraživačkog učenja i znanstvenog razmišljanja općenito. Uspješno rješavanje zadatka istraživačkog učenja je nemoguće bez razumijevanja toga da je cilj analizirati učinke pojedinih nezavisnih varijabli i bez shvaćanja potrebe variranja varijabli u eksperimentima na način koji omogućuje valjano zaključivanje. Osim što meta razina osigurava svjesnost ciljeva i razumijevanje strategija koje se mogu primijeniti na zadatku, na toj se razini strategije biraju tako da odgovaraju zahtjevima zadatka, a njihova primjena se prati i vrednuje (Kuhn, 1999, 2002a, 2002b).

Stjecanje metakognitivnog znanja nije važno samo zato što je ono preduvjet uspješnog strateškog djelovanja na istraživačkom zadatku, već ima smisao samo po sebi. Podsjetimo da cilj znanstvenog obrazovanja nije samo stjecanje konceptualnog znanja iz određenih područja znanosti, već i razumijevanje procesa kojima se dolazi do znanja. Učenici moraju

razumjeti istraživačke pristupe i inferencijalna pravila koja omogućuju donošenje valjanih zaključaka i odbacivanje nevaljanih, te shvaćati vezu između korištenja tih pristupa i pravila i stjecanja znanja o kauzalnoj strukturi područja koje istražuju (Kuhn i Pearsall, 1998). Potrebno je, ne samo znati primijeniti određene istraživačke strategije i vještine, nego i razumjeti njihovu vrijednost i ograničenja, te znati kako, kada i zašto ih koristiti ili ne koristiti.

Različita istraživanja pokazuju da učenici nemaju dovoljno razvijenu meta razinu za optimalno istraživačko učenje (Kuhn i sur., 1995; Keselman i Kuhn, 2002; Keselman, 2003). Nepotpuno stjecanje znanja o kauzalnoj strukturi multivarijatnih sustava i nedovoljno napredovanje u korištenju učinkovitih i valjanih istraživačkih vještina i strategija nije uvjetovano samo nedostacima na razini izvedbe, nego i nedostacima na meta razini (Kuhn i sur., 1995; Kuhn, 2001b). Mikrorazvojna istraživanja bez iznimke pokazuju da učenici ne koriste konzistentno istraživačke strategije i vještine koje su već usvojili, pa se u repertoaru njihovih istraživačkih pristupa tijekom dužih razdoblja nalaze i kontrolirane i nekontrolirane usporedbe, i valjani i nevaljani zaključci, što sugerira da učenici ne razumiju prednosti valjanih strategija i ne prepoznaju nužnost njihovog korištenja za valjano zaključivanje o odnosima između varijabli.

Rezultati ovog istraživanja ne odstupaju od ovih općih nalaza drugih mikrorazvojnih istraživanja. Na početku istraživanja, u trenutku kad učenici nemaju neposredno iskustvo rada na zadatku, razumijevanje prirode i zahtjeva zadatka, kao i razumijevanje strategija koje su primjenjive na zadatku se pokazuje sasvim nedostatnim. Ciljem zadatka učenici većinom smatraju ostvarivanje pozitivnog ishoda, a tek manji dio postiže razinu koju znači usmjerenost učenika na analizu učinaka koji dovode do određenih ishoda. Poznavanje strategija rada na zadatku još je na nižoj razini – učenici ili nemaju svijest o potrebi korištenja strateškog pristupa na zadatku ili predlažu pristupe koji omogućuju ostvarivanje pozitivnog ishoda.

Ovi nalazi o niskom početnom metakognitivnom znanju sugeriraju da se razumijevanje zahtjeva zadatka može očekivati i potaknuti tek onda kad učenici počinju raditi na zadatku, odnosno kad počinju stjecati izravno iskustvo eksperimentiranja i zaključivanja. U takvoj situaciji početnog rada na zadatku, učenici započinju eksperimentiranje uglavnom s ciljem postizanja pozitivnih ishoda ili s ciljem otkrivanja učinaka do kojih dovode različite kombinacije čimbenika (što je u skladu s njihovim razumijevanjem cilja i strategija rada na zadatku), ali već prvo mjerenje završavaju s prilično različitim rezultatima na razini

izvedbe. Dok neki učenici već u prvom mjerenju postižu strateški uspjeh i više od 50% valjanih zaključaka, drugi ne donose niti jedan valjani zaključak. Ovi rezultati upućuju na mogućnost različitih putova razvoja i odnosa između strateške i metastrateške razine tijekom rada na zadatku. Ti su odnosi tijekom pojedinih faza rada na zadatku istraženi i analizirani u sklopu kvalitativne analize procesa istraživačkog učenja, prikazane u drugom dijelu poglavlja «Rezultati i rasprava».

Rezultati istraživanja, nadalje, pokazuju da metakognitivno znanje o cilju i strategijama rada na zadatku napreduje uslijed rada na zadatku kod svih učenika. O tome indirektno govori već i podatak o povećanju broja eksperimenata koji se izvode s ciljem utvrđivanja učinka pojedinih čimbenika, s obzirom da takva usmjerenost učenika sugerira njihovo razumijevanje potrebe usmjeravanja analize na jedan čimbenik. Svi su učenici napredovali barem u jednoj sastavnici metakognitivnog znanja (znatno češće u razumijevanju cilja zadatka), a nešto manje od polovice učenika pokazalo je napredak u obje sastavnice. Veće napredovanje u razumijevanju cilja zadatka u odnosu na razumijevanje strategija rada može se povezati s činjenicom da su tijekom rada na zadatku učenicima postavljena pitanja koja su im mogla služiti kao znakovi koji im pomažu u razumijevanju ciljne strukture zadatka. U tome smislu učenicima je posebno moglo pomoći to što su nakon svake situacije rada na zadatku sudjelovali u razgovorima o vlastitim teorijama o učincima pojedinih čimbenika na uništenje šuma. Iz postavljenih su pitanja (*«Što si zaključio o utjecaju pojedinih čimbenika na uništenje šuma?»* i *«Utječe li ili ne utječe čimbenik X na stupanj uništenja šuma?»*) učenici mogli shvatiti da je cilj zadatka analiziranje učinaka pojedinih čimbenika. Postavljena im pitanja, međutim, nisu pružala informacije o mogućim ili poželjnim strategijama rada na zadatku, a manje su ih i usmjeravala na razmišljanje o njima (iako se može pretpostaviti da odgovaranje na pitanje *«Kako znaš da čimbenik X ima (ili nema) utjecaj?»* može osvijestiti korištenje određenih istraživačkih pristupa).

Rezultati istraživanja također pokazuju da svi učenici koji su postigli visoke razine metastrateškog znanja (razine «5» i «6», koje označavaju da učenici razumiju da je potrebno uspoređivati eksperimente koji se međusobno razlikuju samo po razini jedne varijable), postižu barem razinu «3» u metakognitivnom znanju o cilju zadatka. To upućuje na zaključak da je razumijevanje potrebe korištenja kontroliranih usporedbi eksperimenata povezano s razumijevanjem analize učinaka čimbenika kao cilja zadatka, čak i onda kad učenici ne iskazuju potpuno razumijevanje usmjerenosti na analiziranje svakog pojedinog

čimbenika, već se zadržavaju na razini analize toga što utječe na uništenje šuma, bez posebnog izdvajanja pojedinih čimbenika.

S druge strane, gotovo 50% učenika koji postižu više razine metakognitivnog znanja o cilju zadatka (razine «3» do «5»), zastaje na najnižoj razini metastrateškog znanja. To su učenici koji razumiju da je cilj utvrditi što (koji čimbenici) utječe na uništenje šuma, ali ne uspijevaju eksplicirati kako takav cilj ostvariti. Podaci istraživanja, međutim, pokazuju da ovi učenici nisu osuđeni na strateški neuspjeh, usprkos činjenici što im je metastrateško razumijevanje na razini «0». Naime, čak 80% ovih učenika postiže više od 50% valjanih zaključaka u zadnjem mjerenju. Time se pokazuje da je za postizanje strateškog uspjeha dovoljna već analitička usmjerenost koju osigurava razumijevanje cilja zadatka kao onog u kojem se ispituje što utječe na uništenje šuma, dok eksplicitno metastrateško znanje nije nužno.

Po ovome se nalazu, ovo istraživanje razlikuje od rezultata istraživanja Kuhn i Pearsall (1998) koje utvrđuju da na višim meta razinama osnovnu prepreku ostvarivanja strateškog uspjeha predstavlja upravo nedostatak strategija za odgovaranje na cilj zadatka. U tom istraživanju učenici, koji su razumjeli da je cilj zadatka analizirati učinke pojedinih varijabli, ali koji nisu poznavali valjane strategije eksperimentiranja, nisu pokazali uspješno djelovanje na razini izvedbe. To je ujedno bila jedina situacija u kojoj je razumijevanje na meta razini premašilo postignuće koje je pokazano u izvedbi.

Ove se razlike u nalazima istraživanja vjerojatno mogu povezati s činjenicom da su u istraživanju Kuhn i Pearsall (1998) učenici općenito donosili značajno manje valjanih zaključaka, pa je napredovanje u razumijevanju strategije kontrole varijabli omogućilo veliki skok u strateškoj izvedbi. Osim toga, potrebno je ukazati na to da je u istraživanju Kuhn i Pearsall (1998) metakognitivno znanje ispitivano usmeno (uz postavljanje potpitanja ukoliko je bilo potrebno), dok su u ovom istraživanju korišteni pismeni odgovori učenika. Moguće je da je u uvjetima pismenog izražavanja metakognitivnog razumijevanja izrazitije došla do izražaja činjenica da učenici mogu razumjeti više nego što su sposobni i spremni izraziti, pa da učenici nisu uspjeli prikladno prenijeti svoje metastrateško razumijevanje i učiniti ga eksplicitnim. O tome da određeno metastrateško razumijevanje koje upućuje na primjenu valjanih strategija eksperimentiranja i zaključivanja ipak postoji (barem kod dijela ovih učenika koji se nalaze na razini «0»), govore njihove izjave koje prate biranje čimbenika za pojedine eksperimente npr. *«sve ću ostaviti isto, samo ću uzeti*

*drugu vrstu šuma»* ili *«promijenit ću samo tlo»<sup>53</sup>*, koje sugeriraju da učenici implicitno razumiju potrebu variranja jednog čimbenika po eksperimentu, iako nisu sposobni to izraziti i objasniti kad ih se izravno pita o prikladnim strategijama rada na zadatku.

Nadalje, analiza odnosa meta razine i uspješnosti rada na zadatku istraživačkog učenja na cijelom uzorku učenika pokazuje da je postizanje više razine metakognitivnog znanja povezano s boljim strateškim djelovanjem na zadatku, s većim korištenjem strategije kontrole varijabli i većom valjanosti zaključaka, te sa stjecanjem boljeg razumijevanja kauzalne strukture modela zadatka. Utvrđeno je da učenici ne pokazuju uspješno strateško djelovanje ukoliko ne dosižu određenu razinu metakognitivnog razumijevanja (barem razinu «3»). Međutim, čak i ostvarivanje najviših razina metakognitivnog razumijevanja (razine «5» i «6») ne garantira postojanje potpunog strateškog uspjeha. Time se potvrđuje nalaz Kuhn i Pearsall (1998) o tome da je razvijena meta razina nužan, ali ne i dovoljan uvjet za postizanje strateškog uspjeha. Iako su strateška i metastrateška razina uglavnom usklađene, pa se rijetko događa da su korištene strategije na razini izvedbe naprednije od razine razumijevanja koje učenik postiže na meta razini, postoje slučajevi u kojima je meta razina jača od strateške razine. U tim slučajevima, učenici znaju da je cilj utvrditi učinak pojedinih čimbenika na uništenje šuma i razumiju potrebu sustavnog i strateškog djelovanja, ali ipak provode eksperimente na neorganiziran i nesustavan način, ili tako da valjane strategije ne koriste konzistentno. Može se pretpostaviti da razlozi nekorištenja metakognitivnog znanja mogu biti različiti: s jedne strane motivacijski (npr. zadatak može biti učeniku nezanimljiv ili nevažan, a primjena metakognitivnog znanja na zadatku zahtijeva ulaganje napora (postoje negativni poticaji vezani uz aktivnost rada), a s druge strane strateški (učenik možda ne posjeduje istraživačke vještine potrebne za valjano eksperimentiranje i zaključivanje) ili metakognitivni (učenik nema razvijene vještine planiranja, praćenja, vrednovanja i regulacije procesa učenja).

Rezultati istraživanja, nadalje, pokazuju da do napredovanja u razumijevanju cilja i strategija rada na zadatku ne dolazi na transfernom zadatku koji traži primjenu metakognitivnog znanja. U tom zadatku od učenika se traži da na konkretnom primjeru pokažu razumijevanje cilja zadatka (identificiranje učinka pojedinih čimbenika) i toga zašto je strategija kontrole varijabli najbolja strategija za postizanje tog cilja. Pokazuje se

---

<sup>53</sup> O metastrateškom razumijevanju govori i podatak o tome da je ukupno 83% donesenih valjanih zaključaka o pojedinom čimbeniku koordinirano s namjerom ispitivanja tog čimbenika. To upućuje na zaključak da je usporedba koja vodi k valjanom zaključivanju velikim dijelom intencionalna i planirana, a vjerojatno izvedena i s razumijevanjem korisnosti takve usporedbe za utvrđivanje učinka pojedinog čimbenika.



da na takvom zadatku učenici pokazuju tendenciju vraćanja na razinu koja predstavlja inženjerski pristup u eksperimentiranju (Schauble i sur., 1991), odnosno na pristup kojem je cilj utvrditi optimalnu kombinaciju čimbenika koja dovode do poželjnog ishoda. Transfer vjerojatno otežava činjenica da je korišten transferni zadatak iz područja svakodnevnog života, budući da istraživanje pokazuje da učenici koji rade na zadatku iz socijalnog područja iskazuju niže razine metastrateškog razumijevanja od učenika koji rade na zadatku iz prirodoslovnog područja (Kuhn i Pearsall, 1998).

Ovaj nalaz o nedovoljnom prenošenju novo stečenog metakognitivnog znanja u novu situaciju nije bio sasvim očekivan. Pod pretpostavkom da su strategije koje učenici stječu tijekom rada na zadatku istraživačkog učenja neovisne o području i primjenjive u različitim područjima, kao i pod pretpostavkom da učenici koji uče primjenjivati te strategije u kontekstu jednog sadržaja, mogu primijeniti iste strategije na drugi sadržaj (Kuhn i sur., 1992, 1995), očekivalo se da bi povećano metakognitivno razumijevanje zahtjeva zadatka i povećana svjesnost strategija mogli učiniti te strategije dostupnijima i osigurati da se one generaliziraju i primijene na drugoj situaciji u kojoj su prikladne (Kuhn i sur., 2000; Kuhn, 2002b).

Do toga, međutim, nije došlo. Učenici nisu prepoznali primjenjivost stečenih valjanih istraživačkih strategija, usprkos tome što transferni zadatak koristi identični model zadatka (na drugom sadržaju) i zahtijeva iste aktivnosti kakve su već korištene na zadatku o uništenju šuma.

Moguće je pretpostaviti da je za transfer na novu situaciju potrebno dodatno konsolidiranje metakognitivnih dobitaka koji su ostvareni kroz uvježbavanje istraživačkih pristupa na zadatku o uništenju šuma. Međutim, moguće je da učenici na transfernom zadatku nisu pokazali poboljšano metakognitivno razumijevanje rada, barem dijelom zbog načina na koji je taj zadatak postavljen. Naime, u tom zadatku dvoje izmišljenih učenika ne slaže se oko toga kako provesti drugi eksperiment, a učenik treba odabrati bolji pristup te obrazložiti svoj izbor. Imajući na umu da su na zadatku o uništenju šuma učenici često započinjali eksperimentiranje biranjem kombinacije s određenim (minimalnih) ishodom, čak i onda kad su razumijevali da je potrebno koristiti strategiju kontrole varijabli, zato da bi im ta minimalna kombinacija služila kao referentna točka za usporedbu s drugim eksperimentima, moguće je da učenici u transfernom zadatku nisu uviđali potrebu da već drugi eksperiment postave na način koji omogućuje valjanu usporedbu s prvim eksperimentom, zato što su smatrali potrebnim prvo uspostaviti optimalnu kombinaciju

čimbenika. Moguće je stoga pretpostaviti da prikazivanje prva dva eksperimenta ne potiče učenike na razmišljanje na valjani način, iako možda razumiju potrebu ispitivanja učinka pojedinih čimbenika (a ne produciranja određenog eksperimentalnog ishoda). Ukoliko je ova pretpostavka točna, vjerojatno je da bi učenici, bez obzira na loš početni rezultat na transfernom zadatku, vjerojatno brže napredovali u radu na njemu (u odnosu na zadatak o uništenju šuma), u slučaju da im je pružena prilika «stvarnog» eksperimentiranja na tom novom sadržaju. Dakako, ovo istraživanje nije omogućilo ispitivanje ovakve pretpostavke, ali su neka druga istraživanja ukazala na takvu mogućnost (npr. Kuhn i sur., 1992, 1995).

Rezultati drugih istraživanja također ukazuju na ograničenost transfera metakognitivnog razumijevanja. Kuhn i suradnici (2000) su procjenjivali razumijevanje cilja zadatka i razumijevanje strategije kontrole varijabli, na temelju zadatka koji se po sadržaju razlikovao od onog koji su učenici vježbali, slično kao u ovom istraživanju. Čak i u skupini koja je sudjelovala u eksperimentalnom tretmanu za jačanje metakognitivnog znanja, tek je oko polovine učenika iskazalo jasno metastrateško razumijevanje. Značajan broj učenika je izabrao točan plan, ali nisu ponudili valjano objašnjenje takvog izbora, što sugerira da je njihovo implicitno razumijevanje (koje se očituje u izboru valjanog plana eksperimentiranja) značajno snažnije od njihovog eksplicitnog razumijevanja (koje se očituje u objašnjenjima koja daju za svoj izbor). Ipak, u odnosu na kontrolnu skupinu, učenici iz eksperimentalne skupine su bolje objašnjavali superiornost plana za odgovaranje na cilj zadatka (prepoznali su vrijednost strategije kontrole varijabli), pa se potvrdilo da vježbanje meta razine razvija metakognitivno razumijevanje važnosti koju ima eksperimentalna kontrola za utvrđivanje učinaka nezavisnih varijabli.

Slične rezultate o nepotpunom metakognitivnom razumijevanju nakon sudjelovanja u vježbi predviđanja rezultata eksperimenata ili u direktnoj poduci o predviđanjima dobivaju i Keselman i Kuhn (2002), kao i Keselman (2003), pa zaključuju da je za veće dobitke i transfer učenja potrebno više sustavne prakse, kao i podučavanje na primjerima iz različitih područja. Zohar i Ben David (2008) koji su eksplicitno poučavali učenike metastrateškom znanju o strategiji kontrole varijabli također ukazuju na problem transfera s metastrateškog znanja o pojedinim varijablama na opće metastrateško znanje s generaliziranim pravilima, te navode da se za neke učenike taj prijelaz ne događa spontano.

Imajući u vidu da ovi nalazi proizlaze iz istraživanja koja kroz različite intervencije pokušavaju direktno poticati razvoj meta razine, rezultati o nepostojanju transfera metakognitivnog razumijevanja u ovom istraživanju nisu iznenađujući.

Naime, ovo istraživanje, kao i druga mikrorazvojna istraživanja istraživačkog učenja (Kuhn i sur., 1992, 1995; Schauble, 1990, 1996), pokazuju da je sudjelovanje učenika u ponavljanim situacijama istraživačkog učenja, čak i bez posebne povratne informacije o uspješnosti rada učenika na zadatku, samo po sebi dovoljno za induciranje promjena na strateškoj i metastrateškoj razini. Međutim, pokazuje se da ostvarene promjene nisu nužno održive ili prisutne kod svih učenika, pa se o uvježbavanju istraživačkih vještina i strategija kroz ponavljani rad na istom zadatku ne može govoriti kao o optimalnoj metodi poticanja promjena, već samo kao o minimalnim uvjetima ostvarivanja (meta)strateških promjena. Kod nekih učenika sudjelovanje u ponavljanim situacijama samostalnog eksperimentiranja nije dovoljno za postizanje (značajnog) napredovanja na strateškoj i meta razini. Kuhn (2001b, 2002b) pretpostavlja da se tu radi o učenicima kod kojih je meta razina suviše slaba da bi mogla iskoristiti povratne informacije koje se pojavljuju kao rezultat strateškog djelovanja.

Jačanje istraživačkih vještina i strategija kod svih učenika, kao i ostvarivanje boljih rezultata učenja očito zahtijeva snažnije intervencije (Keselman i Kuhn, 2002). Razmišlja se o tome kako direktno potaknuti metakognitivno razumijevanje, umjesto pustiti da se spontano razvija kao rezultat uvježbavanja istraživačkih vještina i strategija (Kuhn i sur., 2000). Utvrđeno je da intervencije koje imaju za cilj inducirati promjene na razini izvedbe ostvaruju ograničeni uspjeh, ukoliko istovremeno ne utječu na meta razinu (Kuhn, 2001b, 2002a). Primjerice, direktno poučavanje strategije kontrole varijabli, koje je intervencija usmjerena na razinu izvedbe, uspijeva učenike naučiti izvoditi strategiju kontrole varijabli, ali im ne pomaže u razumijevanju toga zašto, kada i kako koristiti tu strategiju u odgovaranju na ciljeve zadatka, niti osigurava da će ta strategija biti odabrana u trenutku kad se učenik nađe u situaciji koja od njega zahtijeva samostalno eksperimentiranje (Kuhn i Dean, 2005). Da bi se osigurao uspješan transfer na nove situacije učenja, potrebno je izravno jačati meta razinu (Keselman i Kuhn, 2002; Keselman, 2003).

## **5.5. Uloga motivacije i metakognitivnog doživljaja zadatka u procesima i ishodima istraživačkog učenja**

Kao uvod u ispitivanje uloge motivacije i metakognitivnog doživljaja zadatka istraživačkog učenja u procesima i ishodima istraživačkog učenja, u nastavku je dat kratak prikaz rezultata o promjenama u motivacijskim, emocionalnim i metakognitivnim procjenama zadatka kroz četiri mjerenja na cijelom uzorku učenika. Te će procjene poslužiti za profiliranje učenika u skupine koje se međusobno razlikuju po doživljaju zadatka. U analizama koje slijede pokušat će se dobiti odgovor na pitanje o tome razlikuju li se ti različiti profili učenika po pristupu koji zauzimaju u radu na zadatku, kao i po učinku koji ostvaruju. Time će se odgovoriti na treće istraživačko pitanje.

### ***5.5.1. Promjene motivacijskih, metakognitivnih i emocionalnih procjena tijekom rada na zadatku***

#### *Motivacijske procjene vezane uz zadatak istraživačkog učenja*

U tablici 35 prikazane su aritmetičke sredine i standardne devijacije motivacijskih procjena koje su učenici davali prije i poslije rada na zadatku u četiri situacije istraživačkog učenja.

Iz tablice 35 je vidljivo da su prosječne vrijednosti motivacijskih procjena koje učenici daju prije početka rada na zadatku u prvoj situaciji istraživačkog učenja izrazito visoke i ograničene na pozitivni dio ljestvica. Totalni raspon procjena sviđanja zadatka, procjena interesa za zadatak i važnosti postizanja uspjeha na zadatku kreće se između neutralne i krajnje pozitivne vrijednosti (od 3 do 5). Osim što većina učenika daje pozitivne procjene sviđanja i interesa za prikazani istraživački zadatak, učenici se uglavnom pozitivno izjašnjavaju i o vlastitom doživljaju kompetentnosti za rješavanje tog zadatka. Tek po jedan učenik daje procjenu samoeфикаsnosti koja se nalazi u negativnom i neutralnom dijelu ljestvice, dok se ostali učenici raspodjeljuju između kategorija 'osjećam se izrazito sposoban/na' i 'uglavnom sposoban/na'. Od svih motivacijskih procjena, u prvom mjerenju prije početka rada na zadatku o uništenju šuma najniža procjena je prisutna za mjeru 'očekivanje uspjeha na zadatku', što je nalaz koji se može povezati s novošću koju situacija rada u programu FILE predstavlja za učenike, kao i s malom poznatošću predstavljenog istraživačkog zadatka.

Tablica 35

Aritmetičke sredine i standardne devijacije motivacijskih procjena prije i poslije rada na zadatku u četiri mjerenja

		Prvo mjerenje		Drugo mjerenje		Treće mjerenje		Četvrto mjerenje	
		<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Sviđanje zadatka	Prije	4,12	,600	3,94	,747	3,70	0,883	3,64	0,962
	Poslije	4,24	,663	3,94	,827	3,97	0,883	3,94	1,029
Interes za zadatak	Prije	4,06	,747	3,76	,867	3,48	1,121	3,55	1,063
	Poslije	4,27	,761	4,03	,918	3,76	0,969	3,73	1,069
Važnost uspjeha	Prije	3,85	1,064	3,61	1,197	3,64	1,113	3,58	1,091
	Poslije	3,91	,980	3,79	1,166	3,61	1,029	3,61	1,088
Samoeфикаsnost	Prije	4,18	,635	4,30	,728	4,36	0,653	4,42	0,663
	Poslije	-	-	-	-	-	-	-	-
Očekivanje uspjeha	Prije	3,73	,626	3,97	,637	4,06	0,747	4,18	0,584
	Poslije	-	-	-	-	-	-	-	-

Analize varijance s ponovljenim mjerenjima dvije nezavisne varijable 'redni broj mjerenja' i 'prije-poslije rada na zadatku'<sup>54</sup>, čiji su rezultati prikazani u tablici 36, pokazuju da od prvog do četvrtog mjerenja padaju procjene sviđanja i interesa za zadatak, a raste procjena očekivanja uspjeha na zadatku. Pritom, učinci su najveći između prvog i drugog mjerenja, dok se između kasnijih mjerenja značajno smanjuju.

Uz statistički značajne učinke 'rednog broja mjerenja', za procjene sviđanja i interesa za zadatak dobiveni su i značajni učinci 'prije–poslije rada na zadatku'. Učeničke procjene sviđanja zadatka i interesa za zadatak veće su nakon rada na zadatku nego prije rada (neovisno o tome o kojem mjerenju je riječ).

Procjene samoeфикаsnosti i važnosti postizavanja uspjeha na zadatku ne mijenjaju se kroz četiri mjerenja.

Prosječne vrijednosti motivacijskih procjena s kojima učenici završavaju rad na zadatku istraživačkog učenja pokazuju da oni uspijevaju zadržati pozitivnu motivaciju i pozitivne procjene zadatka, usprkos činjenici da su četiri puta rješavali potpuni isti zadatak. Čak se i najmanje pozitivna procjena, ona koja je dodijeljena za interes na zadatku, nalazi u pozitivnom dijelu ljestvice, iznad vrijednosti 3,5.

<sup>54</sup> Analize varijance se temelje na rezultatima 33 učenika. Jedan učenik nije imao podatke u trećem i četvrtom mjerenju zbog ranijeg završavanja rada na zadatku.

Tablica 36

Rezultati analize varijance s ponovljenim mjerenjima dvije nezavisne varijable: redni broj mjerenja i prije – poslije rada na zadatku istraživačkog učenja

		Mauchlyjev test $\chi^2(5)$	<i>F</i>	<i>df</i>	<i>p</i>
Svidanje zadatka	Redni broj mjerenja	10,09	6,23	3, 96	<b>,001</b>
	Prije - poslije	-	7,23	1, 32	<b>,011</b>
	Redni broj mjerenja * Prije - poslije	6,16	1,60	3, 96	,195
Interes za zadatak	Redni broj mjerenja	10,11	10,41	3, 96	<b>&lt;,001</b>
	Prije - poslije	-	13,73	1, 32	<b>,001</b>
	Redni broj mjerenja * Prije - poslije	26,37***	0,13	2,08, 66,45	,886
Važnost uspjeha	Redni broj mjerenja	12,30*	2,80	2,35, 75,32	,058
	Prije - poslije	-	2,07	1, 32	,160
	Redni broj mjerenja * Prije - poslije	10,61	0,72	3, 96	,545
Samoefikasnost	Redni broj mjerenja	9,15	1,45	3, 96	,234
Očekivanje uspjeha	Redni broj mjerenja	10,23	5,03	3, 96	<b>,003</b>

\*  $p < ,05$  \*\*\* $p < ,001$

*Metakognitivni doživljaj zadatka istraživačkog učenja*

U tablici 37 prikazane su aritmetičke sredine i standardne devijacije procjena metakognitivnog doživljaja danih prije i poslije rada na zadatku u četiri situacije učenja, a u tablici 38 predstavljeni su rezultati analiza varijanci s ponovljenih mjerenjima za te mjere.

Tablica 37

Aritmetičke sredine i standardne devijacije metakognitivnog doživljaja zadatka istraživačkog učenja prije i poslije rada na zadatku u četiri mjerenja

		Prvo mjerenje		Drugo mjerenje		Treće mjerenje		Četvrto mjerenje	
		<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Osjećaj težine zadatka	Prije	2,06	,864	1,82	,808	1,82	0,882	1,88	0,857
	Poslije	2,12	1,023	1,97	,883	1,94	0,788	1,88	0,781
Procjena potrebe ulaganja truda	Prije	3,79	,820	4,03	,847	3,82	0,983	3,88	0,960
	Poslije	-	-	-	-	-	-	-	-
Namjera ulaganja truda/ Uloženi trud	Prije	4,09	,723	4,03	,728	4,00	0,707	3,85	0,795
	Poslije	4,06	,933	3,82	,882	3,97	0,770	3,91	0,843
Procjena uspješnosti rada	Prije	-	-	-	-	-	-	-	-
	Poslije	3,97	,684	4,09	,765	4,12	0,650	4,36	0,653
Procjena točnosti rješenja	Prije	3,70	,585	3,82	,635	4,09	0,579	4,15	0,508
	Poslije	3,88	,600	4,15	,667	4,06	0,609	4,24	0,561
Uvjerenost u točnost rješenja	Prije	-	-	-	-	-	-	-	-
	Poslije	4,15	,619	4,30	,529	4,33	0,540	4,52	0,508

Prije početka rada na zadatku, u situaciji kad je učenicima predstavljen program FILE i opisan problem «Uništenje šuma», učenici zadatak uglavnom ne ocjenjuju teškim. Procjene svih učenika (osim jednog) kretale su se u rasponu od «zadatak uopće nije težak» do «niti je težak, niti lagan». Osjećaj težine zadatka je stabilan tijekom rada na zadatku – nema statistički značajnih razlika između pojedinih mjerenja, kao ni između procjena prije i poslije rada na zadatku unutar pojedinih situacija učenja.

Bez obzira na prosječno niski osjećaj težine zadatka o uništenju šuma, učeničke procjene potrebe ulaganja truda i namjere ulaganja truda relativno su visoke, kao i procjene uloženog truda, koje iznose oko 4 i odgovaraju kategoriji «ulažem mnogo truda». Te se procjene također ne razlikuju statistički značajno između pojedinih mjerenja, već se zadržavaju na istoj razini od početka do kraja istraživanja. Osim toga, nema statistički značajnih razlika između procjena truda prije i poslije rada na zadatku unutar pojedinih mjerenja.

Tablica 38

Rezultati analize varijance s ponovljenim mjerenjima dvije nezavisne varijable: redni broj mjerenja i prije – poslije rada na zadatku istraživačkog učenja

		Mauchlyjev test $\chi^2(5)$	F	df	p
Osjećaj težine zadatka	Redni broj mjerenja	10,70	2,22	3, 96	,091
	Prije - poslije		1,52	1, 32	,227
	Redni broj mjerenja * Prije - poslije	24,90***	0,24	2,21, 70,56	,870
Procjena potrebe ulaganja truda	Redni broj mjerenja	14,74*	1,19	2,29, 73,37	,313
Namjera ulaganja truda	Redni broj mjerenja	7,27	1,96	3, 96	,125
Uloženi trud	Redni broj mjerenja	9,64	2,07	3, 96	,110
Procjena uspješnosti rada	Redni broj mjerenja	3,27	4,25	3, 96	<b>,007</b>
Očekivana točnost rješenja	Redni broj mjerenja	22,30***	7,93	2,16, 69,16	<b>,001</b>
Procjena točnosti rješenja	Redni broj mjerenja	1,46	4,28	3, 96	<b>,007</b>
Uvjerenost u točnost rješenja	Redni broj mjerenja	4,23	3,91	3, 96	<b>,011</b>

\* p<,05 \*\*\*p<,001

Procjene uspješnosti rada na zadatku (procjene ostvarenog rezultata), procjene točnosti rješenja zadatka te procjene uvjerenosti u točnost ponuđenog rješenja (odnosno u točnost izjava o učincima čimbenika na uništenje šuma) također su relativno visoke već od prvog mjerenja. Prosječne procjene se nalaze oko vrijednosti 4. Do kraja rada na zadatku te

procjene još i rastu. Kad se radi o procjeni uspješnosti rada na zadatku i uvjerenosti u točnost vlastitih zaključaka, ispitivanje kontrasta ponovljenih mjerenja pokazuju da su (po statističkoj značajnosti i veličini učinka) relevantni kontrasti dobiveni između trećeg i četvrtog mjerenja, kad dolazi do značajnog porasta u prosječnim vrijednostima ovih mjera. Učenici završavaju rad na zadatku uvjereni u ostvarenje vrlo dobrog do izvrsnog rezultata, kao i gotovo potpuno uvjereni u točnost zaključaka koje su donijeli.

#### *Emocionalne procjene pri radu na zadatku istraživačkog učenja*

Prosječne vrijednosti procjena raspoloženja za rad na zadatku (prikazane u tablici 39) pokazuju da učenici započinju rad na zadatku o uništenju šuma vrlo dobro raspoloženi. Međutim, od prvog do četvrtog mjerenja pada raspoloženje za rad na zadatku (vidi tablicu 40). Ipak, čak i završne procjene, odnosno procjene dane u četvrtom mjerenju, pokazuju da učenici ostaju uglavnom dobro raspoloženi za rad.

*Tablica 39*  
Aritmetičke sredine i standardne devijacije procjena raspoloženja za rad na zadatku i faktora 'emocionalno stanje' u četiri mjerenja

		Prvo mjerenje		Drugo mjerenje		Treće mjerenje		Četvrto mjerenje	
		<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Raspoloženje za rad na zadatku	Prije	4,30	,637	3,91	,914	3,82	0,769	3,70	0,951
Emocionalno stanje	Prije	5,78	,960	6,26	,891	6,32	,943	6,35	1,143
	Poslije	6,39	,791	6,49	,876	6,53	,717	6,59	,862

Emocionalne procjene, koje su učenici davali na bipolarnih ljestvica od sedam stupnjeva, grupirane su u faktor 'emocionalno stanje'<sup>55</sup>, pri čemu veći rezultat označava pozitivnije

<sup>55</sup> Na šest čestica emocionalnog stanja (dobro - loše, napeto - opušteno, zadovoljno – nezadovoljno, smireno – uznemireno, umorno – odmorno, nesiguran u sebe – siguran u sebe) provedene su eksplorativne faktorske analize zasebno za svako mjerenje, odnosno zasebno za situacije prije i poslije rada na zadatku. Zbog opsežnosti, rezultati tih faktorskih analiza nisu detaljnije prikazani. Korištena je analiza glavnih komponenta i varimax rotacija. U pet faktorskih analiza izlučen je samo jedan faktor s eigen vrijednošću iznad 1 koji objašnjava između 57,34 i 75,99% varijance rezultata. Najmanji i nezadovoljavajuće niski komunaliteti dobiveni su za česticu 'umorno – odmorno' (između ,066 i ,315). U dvije faktorske analize izdvojio se drugi faktor na kojem je najveće zasićenje imala čestica 'umorno – odmorno'. U jednoj faktorskoj analizi također su izlučena dva faktora, ali faktorska struktura nije bila jednostavna, jer je četiri od šest čestica imalo projekcije na oba faktora.

Izbacivanjem čestice 'umorno – odmorno' u svim je situacijama mjerenja emocionalnog stanja dobiveno jednofaktorsko rješenje. Faktor «emocionalno stanje» objašnjava između 51,68% (u prvom mjerenju, prije rada na zadatku) i 89,61% varijance rezultata (u četvrtom mjerenju, prije rada na zadatku). Cronbach  $\alpha$  indeks pouzdanosti na standardiziranim vrijednostima za ljestvice od 5 čestica iznosi između ,76 (u prvom mjerenju, prije rada na zadatku) i ,97 (u četvrtom mjerenju, prije rada na zadatku).

Na temelju rezultata faktorske analize, izračunati su faktorski rezultati kao prosjeci vrijednosti pet čestica koje čine faktor (za situacije prije i poslije rada na zadatku u svakom mjerenju).



emocionalno stanje. Prosječne vrijednosti na faktoru (prikazane u tablici 39) pokazuju da je najniža procjena emocionalnog stanja dana u prvom mjerenju, u situaciji prije rada na zadatku. Takva prosječna procjena, koja je jedina od svih procjena bila ispod vrijednosti od 6 stupnja, posljedica je osjećaja blage napetosti, uznemirenosti i nesigurnosti u sebe, koji su bili prisutni prije početka rada kod određenog dijela učenika. Međutim, već s prvom situacijom rada na zadatku dolazi do značajnog skoka u prosječnoj procjeni emocionalnog stanja, pa učenici završavaju prvo mjerenje u prilično pozitivnom općem emocionalnom stanju. U sljedećim mjerenjima procjene emocionalnog stanja ostaju jednako pozitivne (ne razlikuju se međusobno statistički značajno, već samo u odnosu na prvo mjerenje). Utvrđeno je, međutim, da su unutar pojedinih mjerenja procjene emocionalnog stanja nakon rada na zadatku pozitivnije nego procjene dane prije rada. Statistički značajan interakcijski učinak, pak, govori da je razlika prije-poslije u prvom mjerenju veća nego razlike prije-poslije u ostalim mjerenjima.

*Tablica 40*  
Rezultati analize varijance s ponovljenim mjerenjima u procjenama raspoloženja i faktoru 'emocionalno stanje'

		Mauchlyjev test $\chi^2(5)$	F	df	p
Raspoloženje za rad na zadatku	Redni broj mjerenja	10,22	7,94	3, 96	<b>&lt;,001</b>
Emocionalno stanje	Redni broj mjerenja	36,94***	5,91	1,72, 55,06	<b>,007</b>
	Prije - poslije		37,82	1, 32	<b>&lt;,001</b>
	Redni broj mjerenja * Prije - poslije	22,40***	4,29	2,03, 64,92	<b>,017</b>

\*\*\*p<,001

Na temelju ovih nalaza, može se zaključiti da su učenici prije početka rada na zadatku imali blagu tremu, koja je nestala već s izloženošću prvoj situaciji rada na zadatku (vjerojatno i s doživljajem uspjeha, barem iz učeničke perspektive) i prepustila učenike relativno stabilnom pozitivnom emocionalnom stanju tijekom cijelog istraživanja.

### **5.5.2. Profiliranje učenika s obzirom na doživljaj zadatka istraživačkog učenja**

#### *Određivanje profila učenika*

Grupiranje ispitanika u relativno homogene skupine učenika ('profile') na temelju njihovog doživljaja zadatka istraživačkog učenja provedeno je pomoću hijerarhijske klaster analize.

Osnovna ideja analize bila je u profiliranju učenika zahvatiti njihova iskustva kroz ponavljane situacije rada na zadatku, te grupiranje učenika provesti na temelju sličnosti njihovih motivacijskih procjena i procjena prospektivnog metakognitivnog doživljaja u sva četiri mjerenja. Uključivanjem međusobno zavisnih mjera iz različitih mjerenja u jednu analizu, različite skupine učenika su identificirane na temelju njihove sličnosti tijekom cijelog istraživanja, a ne samo u jednoj točki mjerenja (npr. na početku istraživanja, kad učenici još nisu niti pristupili procesu eksperimentiranja). Time su se u analizu na određeni način uključili i elementi promjena u ispitivanim mjerama.

Od svih korištenih mjera motivacije, emocija i metakognitivnog doživljaja, za analizu su izdvojene sljedeće mjere, uzete prije početka rada na zadatku u svakom mjerenju:

- interes za zadatak
- samoeфикаsnost
- važnost ostvarivanja uspjeha na zadatku
- očekivanje uspjeha na zadatku
- osjećaj težine zadatka
- namjera ulaganja truda
- emocionalno stanje
- raspoloženje za rad na zadatku

Neke od korištenih mjera motivacije i prospektivnog metakognitivnog doživljaja (npr. osjećaj sviđanja zadatka, procjena točnosti rješenja) isključene su iz analize zbog visokih korelacija s drugim mjerama, odnosno problema multikolinearnosti koji se u klaster analizi očituje kao davanje implicitnog pondera (većeg značaja) koreliranim mjerama u određivanju mjera sličnosti (Hair, Black, Babin i Anderson, 2009). Sličnim problemom može se smatrati korištenje ponavljanih mjera istih varijabli, međutim, njihov je utjecaj na sličnost među entitetima izjednačen korištenjem istog skupa mjera za sva četiri mjerenja.

Prije provedbe klasterizacije, zbog korištenja različitih mjernih ljestvica (ljestvica od pet i sedam stupnjeva), provedena je standardizacija podataka njihovim transformiranjem u z-vrijednosti.

U provedenoj klaster analizi kao mjera udaljenosti između ispitanika korištena je kvadrirana euklidska udaljenost. Spajanje klastera, odnosno povezivanje ispitanika u klaster je temeljeno na Wardovoj metodi, koja u svakom koraku za pojedine ispitanike unutar klastera računa njihovu udaljenost od centroida klastera (prosjeaka svih varijabli), te sumira kvadrate tih udaljenosti za sve članove klastera. Suma kvadrata svih odstupanja se uzima kao mjera pogreške unutar klastera. Klasterizacija se provodi tako da se minimalizira varijabilitet unutar klastera, što znači da se spajaju oni klasteri koji dovode do minimalnog povećanja sume kvadrata pogreške (Field, 2000). Wardova metoda klasterizacije je odabrana zato što rezultira klasterima približno podjednake veličine (Hair i sur., 2009).

U provedenoj hijerarhijskog klaster analizi korišten je aglomeracijski pristup, koji u prvom koraku tretira svakog ispitanika kao zaseban klaster, a postepenim udruživanjem najbližih ispitanika (ili klastera u sljedećim koracima) formiraju se sve veći klasteri, sve do svrstavanja svih ispitanika u isti klaster. Budući da je u analizu bilo uključeno 33 ispitanika, klasterizacija je provedena u 32 koraka.

Određivanje broja klastera koji predstavljaju konačno rješenje je provedeno na temelju razmatranja dendograma i analize razlika u aglomeracijskim koeficijentima između pojedinih sukcesivnih koraka u formiranju klastera<sup>56</sup>. Ti koeficijenti pokazuju sličnost među klasterima pri sukcesivnom spajanju klastera, tako da postojanje naglog skoka u vrijednosti koeficijenta ukazuje na spajanje dva relativno različita klastera, te na opravdanost korištenja klasterskog rješenja iz prethodnog koraka (zbog manje udaljenosti spojenih klastera u tom koraku).

U podacima je opažena relativno velika razlika u vrijednosti aglomeracijskog koeficijenta između 30. i 31. koraka, koji odgovara kombiniranju ispitanika u dva odvojena klastera, pa se formiranje tri klastera moglo smatrati prikladnijim rješenjem. Razlika u koeficijentima između 29. i 30. koraka je bila manja i nije predstavljala jasan skok koji bi ukazivao da je udaljenost spojenih klastera u troklasterskom rješenju mnogo veća nego u prethodnom koraku. Stoga se i troklastersko i četveroklastersko rješenja činilo prihvatljivim. Konačan odabir između njih je napravljen vodeći se načelom parsimonije i uvažavajući činjenicu o postojanju malog uzorka ispitanika i većoj mogućnosti interpretacije klastera u slučaju rješenja s tri klastera. Naime, testiranje razlika između klastera na varijablama korištenim

---

<sup>56</sup> Razmatrani su koraci 31. do 29., koji predstavljaju dvoklastersko, troklastersko i četveroklastersko rješenje. Prikaz rezultata klaster analize dat je u Prilogu.

za njihovo formiranje je pokazalo bolje razlikovanje klastera u troklasterskom, nego u četveroklasterskom rješenju, pa je to rješenje na kraju i zadržano kao konačno rješenje.

Klaster 1 činilo je 13 ispitanika, klaster 2 šest, a klaster 3 14 ispitanika.

U nastavku su opisani rezultati testiranja razlika između ta tri klastera u mjerama koje su korištene za klasterizaciju<sup>57</sup>, kao i rezultati testiranja razlika između četiri mjerenja unutar pojedinih klastera, koji su poslužili za interpretaciju karakteristika klastera i njihovo imenovanje.

U tablici 41 prikazane su centralne vrijednosti određenih mjera koje ostvaruju pojedini klasteri, kao i rezultati testiranja razlika između klastera.

---

<sup>57</sup> Budući da su ispitanici kategorizirani u klaster tako da je maksimalizirana udaljenost između klastera po korištenim varijablama, testiranje statističke značajnosti razlika između klastera nije opravdano u statističkom smislu, ali je korisno za interpretiranje sadržaja klastera.

Tablica 41

Centralne vrijednosti mjera motivacije, emocionalnog stanja i prospektivnog metakognitivnog doživljaja kod učenika koji pripadaju različitim klasterima, te rezultati testiranja statističke značajnosti razlika između klastera

Varijabla	Mjerenje	Klaster 1	Klaster 2	Klaster 3	H(2)	post hoc+
Interes za zadatak	Prvo	4	3,5	5	**	2-3
	Drugo	3	3,5	4	***	1-3, 2-3
	Treće	4	3,5	4	nz	
	Četvrto	3	3,5	4	**	1-3
Osjećaj težine zadatka	Prvo	2	3	2	nz	
	Drugo	2	3	1	*	1-2, 2-3
	Treće	2	2,5	1	nz	
	Četvrto	2	3	1	**	2-3
Samoefikasnost	Prvo	4	4	4	nz	
	Drugo	4	3,5	5	***	1-2, 2-3
	Treće	4	4	5	*	
	Četvrto	4	4	5	***	1-3, 2-3
Namjera ulaganja truda	Prvo	4	4	4,5	**	2-3
	Drugo	4	4	5	***	1-3, 2-3
	Treće	4	4	4	*	
	Četvrto	4	4	4	*	1-3
Važnost ostvarivanja uspjeha na zadatku	Prvo	3	4	5	***	1-3
	Drugo	3	3,5	5	***	1-3, 2-3
	Treće	3	4	4,5	***	1-3
	Četvrto	3	3,5	4	***	1-3, 2-3
Očekivanje uspjeha na zadatku	Prvo	4	3,5	4	nz	
	Drugo	4	4	4	nz	
	Treće	4	4	4	nz	
	Četvrto	4	4	4,5	**	2-3
Raspoloženje za rad na zadatku	Prvo	4	4	5	**	1-3
	Drugo	3	3	5	***	1-3, 2-3
	Treće	3	4	4	***	1-3
	Četvrto	4	3	4	***	1-3, 2-3
Emocionalno stanje prije rada na zadatku	Prvo	6,0	4,1	6,0	*	
	Drugo	6,8	4,7	6,8	***	1-2, 2,3
	Treće	6,8	4,4	7,0	***	1-2, 2,3
	Četvrto	7,0	4,2	7,0	***	1-2, 2,3

\*\*\*  $p < ,001$ , \*\*  $p < ,01$  \*  $p < ,05$

+ navedeni su parovi među kojima postoji statistički značajna razlika uz razinu značajnosti  $p < ,017$ .

U tablici 42 prikazani su rezultati testiranja statističke značajnosti razlika u određenim mjerama između četiri mjerenja unutar pojedinih klastera.

Tablica 42

Rezultati testiranja značajnosti razlika unutar klastera između četiri mjerenja za pojedine mjere motivacije i metakognitivnog doživljaja

	Klaster 1	Klaster 2	Klaster 3
Interes za zadatak	**	nz	nz
Osjećaj težine zadatka	nz	nz	nz
Samoeфикаsnost	nz	nz	**
Namjera ulaganja truda	nz	nz	nz
Važnost ostvarivanja uspjeha na zadatku	nz	nz	nz
Očekivanje uspjeha na zadatku	nz	nz	***
Raspoloženje za rad na zadatku	*	**	*
Emocionalno stanje prije rada na zadatku	***	nz	***

\*\*\*  $p < ,001$ , \*\*  $p < ,01$  \*  $p < ,05$

Iz tablica 41 i 42 je vidljivo da klaster 3 karakteriziraju najpozitivnije motivacijske procjene. Članovima tog klastera u svim je mjerenjima važnost ostvarivanja uspjeha na zadatku veća nego članovima klastera 1 i 2. Uz to, učenici iz ovog klastera procjenjuju zadatak zanimljivijim od drugih klastera (iako se razlika ne pokazuje uvijek statistički značajnom uz Bonferronijevu korekciju). Visoki interes za zadatak ovaj klaster zadržava kroz sva četiri mjerenja, dok za razliku od toga, procjene interesa kod klastera 1 padaju, a kod klastera 2 se zadržavaju na nižoj razini do kraja istraživanja.

Nadalje, klaster 3 daje u pojedinim mjerenjima (osim u prvom) ponešto više procjene samoeфикаsnosti, a i namjera ulaganja truda u rješavanje zadatka je kod tog klastera uglavnom veća nego za klaster 1 ili 2.

Jedino se u očekivanju uspjeha na zadatku klaster 3 uglavnom ne razlikuje od drugih. Zapaženo je, međutim, da je klaster 3 jedini klaster kod kojeg od prvog do četvrtog mjerenja dolazi do povećanja očekivanja uspjeha na zadatku, kao i do porasta osjećaja samoeфикаsnosti. Kod klastera 1 i 2 od prvog do četvrtog mjerenja nema statistički značajnih razlika u ovim motivacijskim mjerama.

Uz navedene razlike u motivacijskim procjenama, klaster 3 daje u svim mjerenjima više procjene raspoloženja za rad na zadatku od klastera 1 i 2 (iako od prvog do četvrtog mjerenja dolazi do pada tih procjena, slično kao i kod klastera 1). Po procjenama emocionalnog stanja, klaster 3 se ne razlikuje od klastera 1, ali su te procjene znatno pozitivnije od procjena klastera 2. Oba klastera (3 i 1) karakterizira rast pozitivnog emocionalnog stanja (rast osjećaja opuštenosti, smirenosti i sigurnosti u sebe) od prvog do četvrtog mjerenja.

Zbog svih navedenih osobina klastera 3, on je u radu nazvan «*učenici pozitivne motivacijske orijentacije*» (klaster ++).

Klaster 1 i 2 međusobno su sličniji, pa se niti u jednom od četiri mjerenja ne razlikuju statistički značajno po procjenama interesa za zadatak, važnosti ostvarivanja uspjeha na njemu, namjeri ulaganja truda, te po očekivanju uspjeha i raspoloženju za rad na zadatku. U tri mjerenja ne razlikuju se niti po procjeni samoefikasnosti.

Klaster 2, međutim, daje negativnije procjene emocionalnog stanja u svim mjerenjima. Gledano po pojedinim česticama koje čine faktor emocionalnog stanja, ispitanici u klasteru 2 osjećaju se manje opušteno, manje zadovoljno, više uznemireno i manje sigurno u sebe.

Osim opaženih razlika u procjenama emocionalnog stanja, klaster 2 daje i ponešto više procjene osjećaja težine zadatka. Iako se ta tendencija pokazuje u svim mjerenjima, jedino je u drugom mjerenju statistički značajna (u tom mjerenju klaster 2 zadatak procjenjuju težim, a sebe manje sposobnima za rješavanje zadatka i od klastera 1 i od klastera 3).

Uzimajući u obzir činjenicu da klaster 1 i 2, općenito govoreći, karakteriziraju manje povoljne motivacijske procjene (u odnosu na klaster 3), kao i to da se ova dva klastera međusobno razlikuju po procjenama emocionalnog stanja, klaster 1 je za potrebe rada nazvan «*učenici negativnije motivacijske orijentacije – pozitivnog emocionalnog stanja*» (klaster +-), a klaster 2 «*učenici negativnije motivacijske orijentacije – negativnijeg emocionalnog stanja*» (klaster --). U nastavku se o ovim klasterima govori kao o različitim motivacijskim profilima učenika.

Na kraju, za opis dobivenih klastera važno je naglasiti kako se oni ne razlikuju statistički značajno prema spolnoj strukturi ( $\chi^2(2)=0,33$ ;  $p=,847$ ), prema prosječnom rezultatu na testu induktivnog rezoniranja ( $H(2)=4,03$ ,  $p=,133$ ), kao niti prema interesu za znanost ( $H(2)=2,10$ ,  $p=,351$ ). Također, ne razlikuju se prema općem školskom uspjehu u sedmom razredu ( $H(2)=1,09$ ,  $p=,581$ ), niti prema ocjenama iz pojedinih prirodoslovnih predmeta ( $H(2)_{\text{bio}}=3,94$ ,  $p=,140$ ;  $H(2)_{\text{fiz}}=0,05$ ,  $p=,977$ ;  $H(2)_{\text{kem}}=0,88$ ,  $p=,644$ ).

### ***5.5.3. Razlike između motivacijskih profila učenika u motivaciji i metakognitivnom doživljaju tijekom rada na zadatku***

Ispitano je razlikuju li se učenici koji pripadaju različitim motivacijskim profilima po metakognitivnom doživljaju i motivacijskim procjenama koje nisu korištene u postupku klasterizacije, a koje su učenici davali tijekom rada na zadatku nakon svakog četvrtog provedenog eksperimenta<sup>58</sup>.

Za potrebe analiza, za svakog su ispitanika uprosječne procjene koje je dao tijekom rada na zadatku u pojedinom mjerenju. Ukoliko su učenici napravili deset ili jedanaest eksperimenata, ti prosjeci uključuju dvije ponavljane mjere (nakon četvrtog i osmog eksperimenta), dok se u slučaju provedenih 12 i više eksperimenata prosjeci temelje na tri ili više ponavljanih mjera.

U tablici 43 prikazani su rezultati testiranja razlika između klastera.

Rezultati pokazuju da učenici koji pripadaju različitim klasterima koji su određeni na temelju motivacijskih, emocionalnih i metakognitivnih procjena danih prije početka rada na zadatku istraživačkog učenja, zadržavaju iste razlike i tijekom rada u četiri mjerenja. Klaster 2 (--) i dalje daje nepovoljnije procjene emocionalnog stanja od drugih klastera. U odnosu na oba klastera, učenici u tom klasteru osjećaju se tijekom rada općenito lošije, napetije i nesigurnije u sebe.

Između klastera 1 (-+) i klastera 2 (--) nema statistički značajnih razlika u ostalim mjerama uzetima tijekom rada na zadatku niti u jednom od četiri mjerenja, pa ovi učenici daju podjednake procjene motiviranosti za rad, samoefikasnosti, težine zadatka i ulaganja truda.

Za razliku od toga, između klastera 2 (--) i 3 (++) postoje statistički značajne razlike gotovo na svim ispitivanim mjerama, pa su oni međusobno najudaljeniji. U svim mjerenjima, klaster 3 (++) osim što doživljuje pozitivnije emocionalno stanje, daje i više procjene samoefikasnosti za rad na zadatku. U tri mjerenja taj klaster procjenjuje zadatak lakšim (dok u prvom mjerenju nema razlike), a vlastitu motivaciju za rad većom. Jedina varijabla u kojoj se ovi klasteri uglavnom ne razlikuju je procjena uloženog truda, iako klaster 3 (++) i tu daje ponešto više procjene.

---

<sup>58</sup> Učenici su procjene motivacije, emocionalnog stanja i metakognitivnog doživljaja zadatka davali i neposredno nakon rada na zadatku unutar pojedinog mjerenja. Međutim, rezultati analiza tih procjena nisu ovdje predstavljeni, zato što nisu posebno informativni u odnosu na rezultate analiza procjena danih prije i tijekom rada na zadatku. Razlike između klastera se zadržavaju nakon rada na zadatku podjednako kao i prije i tijekom rada.



Tablica 43

Centralne vrijednosti mjera motivacije i metakognitivnog doživljaja tijekom rada na zadatku kod učenika koji pripadaju različitim klasterima, te rezultati testiranja statističke značajnosti razlika između klastera

Varijabla	Mjerenje	Klaster 1	Klaster 2	Klaster 3	H (2)	post hoc+
		-+	--	++		
Osjećaj težine zadatka	Prvo	2	2,75	1,5	5,70	
	Drugo	1,67	2,25	1	6,35*	2-3
	Treće	1	2,5	1	8,78**	2-3
	Četvrto	1,67	2	1	7,78*	2-3
Samoeфикаsnost	Prvo	4,5	3,75	4,84	7,01*	2-3
	Drugo	4,67	4	4,88	6,76*	2-3
	Treće	4,5	4	5	8,09*	2-3
	Četvrto	4	4	5	17,47***	1-3, 2-3
Procjena uloženog truda	Prvo	4	4	5	10,00**	1-3, 2-3
	Drugo	4	4	5	8,32*	1-3
	Treće	4	4	4,42	8,85**	1-3
	Četvrto	3	3,67	4	6,87*	1-3
Procjena emocionalnog stanja: loše - dobro	Prvo	7	6,2	7	9,28**	1-2, 2-3
	Drugo	7	5	7	11,29**	1-2, 2-3
	Treće	7	5,63	7	17,91***	1-2, 2-3
	Četvrto	7	4,5	7	24,41***	1-2, 2-3
Procjena emocionalnog stanja: napeto - opušteno	Prvo	6,75	4,2	7	7,05*	2-3
	Drugo	7	4	7	10,08**	1-2, 2-3
	Treće	7	4,75	7	22,59***	1-2, 2-3
	Četvrto	7	4	7	25,04***	1-2, 2-3
Procjena emocionalnog stanja: nesiguran u sebe – siguran u sebe	Prvo	6,5	5	6,75	6,54*	2-3
	Drugo	7	5,17	7	13,35***	1-2, 2-3
	Treće	7	5,75	7	11,39**	1-2, 2-3
	Četvrto	7	4	7	17,96***	1-2, 2-3
Procjena emocionalnog stanja: nemotivirano - motivirano	Prvo	6	5,25	6,84	8,81**	1-3, 2-3
	Drugo	5,33	4,5	7	14,09***	1-3, 2-3
	Treće	5,5	5,8	6,88	7,24*	1-3
	Četvrto	5,5	4,5	6,75	15,31***	1-3; 2-3

\*\*\*  $p < ,001$ , \*\*  $p < ,01$  \*  $p < ,05$

+ navedeni su parovi među kojima postoji statistički značajna razlika uz razinu značajnosti  $p < ,017$ .

Jednako kao i prije rada na zadatku, klasteri 1 (-+) i 3 (++) se tijekom rada na zadatku ne razlikuju po procjenama emocionalnog stanja i procjenama težine zadatka. Među ovim klasterima uglavnom nema razlika niti po procjenama samoeфикаsnosti, iako u zadnjem mjerenju klaster 3 (++) daje više procjene. Međutim, klaster 3 (++) iskazuje veće procjene uloženog truda, te više procjene motiviranosti za nastavak rada od klastera 1 (-+) u svim mjerenjima.

#### 5.5.4. Razlike između motivacijskih profila učenika u procesima i ishodima istraživačkog učenja

Prethodno je poglavlje utvrdilo razlike između učenika različitih motivacijskih profila u motivacijskim i emocionalnim reakcijama, te metakognitivnom doživljaju tijekom rada na zadatku istraživačkog učenja u pojedinim mjerenjima. U nastavku je ispitano razlikuju li se ti različiti profili učenika u pristupu pojedinim situacijama učenja, odnosno u korištenju istraživačkih (kognitivnih) i metakognitivnih vještina i strategija rada na zadatku, te u učinku koji ostvaruju na zadatku.

##### *Korištenje istraživačkih pristupa, vještina i strategija*

U tablici 44 navedene su prosječne vrijednosti koje ostvaruju pojedini klasteri na ispitivanim mjerama istraživačkih vještina i strategija, kao i rezultati testiranja razlika između klastera u četiri mjerenja.

Tablica 44

Centralne vrijednosti mjera istraživačkih vještina i strategija u četiri mjerenja kod učenika koji pripadaju različitim klasterima, te rezultati testiranja statističke značajnosti razlika između klastera

	Mjerenje	Klaster 1 -+	Klaster 2 --	Klaster 3 ++	H (2)	p
<i>Formuliranje pitanja i hipoteza</i>						
Postotak eksperimenata s namjerom ispitivanja jednog čimbenika	Prvo	20	51,2	37,5	0,89	,642
	Drugo	50	45,9	37,3	2,93	,231
	Treće	45,5	68,0	44,6	2,32	,313
	Četvrto	50	48,1	45,9	0,76	,683
Postotak eksperimenata s nejasnim planom	Prvo	10	15	20	1,69	,430
	Drugo	8,3	11,1	10	0,93	,627
	Treće	0	6,4	10	4,73	,092
	Četvrto	0	8,9	0	0,88	,654
Postotak eksperimenata bez hipoteze	Prvo	78,6	72,5	75,9	0,11	,946
	Drugo	45,5	40,0	61,3	1,21	,545
	Treće	45,5	27,9	40,8	1,06	,588
	Četvrto	40,0	35,6	43,3	0,90	,638
<i>Eksperimentiranje</i>						
Prosječan broj varijabli mijenjan po eksperimentu	Prvo	2,4	2,0	2,4	1,91	,385
	Drugo	1,9	1,8	2,1	5,38	,068
	Treće	2,0	1,7	1,9	1,16	,559
	Četvrto	1,7	2,0	2,0	3,02	,221
Spontani broj provedenih eksperimenata	Prvo	10	8,5	10	1,23	,541
	Drugo	10	9,5	11	0,73	,693
	Treće	12	12,5	10	1,21	,547
	Četvrto	10	11,5	10	0,78	,677
Broj jedinstvenih eksperimenata	Prvo	10	9	10	0,01	,998
	Drugo	10	10	10	0,31	,863
	Treće	11	9	10	1,12	,583
	Četvrto	10	9	10	1,23	,554

Mjerenje		Klaster 1	Klaster 2	Klaster 3	H (2)	p
		++	--	++		
<i>Zaključivanje o odnosima između varijabli</i>						
Broj jednostavnih zaključaka po eksperimentu	Prvo	1,1	0,8	1,2	0,96	,618
	Drugo	0,9	0,9	0,9	0,07	,992
	Treće	0,8	0,8	0,7	0,68	,710
	Četvrto	0,6	0,7	0,6	0,76	,683
Postotak valjanih jednostavnih zaključaka	Prvo	50	52,5	42,2	1,40	,540
	Drugo	57,1	56,3	50,0	2,03	,362
	Treće	73,3	66,1	67,5	0,45	,799
	Četvrto	75,0	64,6	52,1	2,61	,271

Između skupina učenika koji pripadaju različitim motivacijskim profilima nisu pronađene statistički značajne razlike niti na jednoj mjeri istraživačkih vještina i strategija; klasteri se međusobno ne razlikuju po korištenim pristupima u formuliranju istraživačkih pitanja i hipoteza, u eksperimentiranju i u zaključivanju o odnosima između varijabli.

#### *Korištenje metakognitivnih vještina planiranja i praćenja rada na zadatku*

U tablici 45 prikazane su prosječne vrijednosti razine planiranja rada na zadatku<sup>59</sup> i broja korištenih funkcija programa FILE, kao pokazatelja korištenja metakognitivnih funkcija planiranja i praćenja rada na zadatku, te rezultati testiranja statističke značajnosti razlika između klastera.

*Tablica 45*

Centralne vrijednosti korištenja metakognitivnih vještina planiranja i praćenja rada na zadatku kod učenika koji pripadaju različitim klasterima, te rezultati testiranja statističke značajnosti razlika između klastera

Mjerenje		Klaster 1	Klaster 2	Klaster 3	H (2)	p
		++	--	++		
Planiranje rada na zadatku:	Prvo	3	2,50	3	0,32	,854
	Drugo	2	2,50	2	0,04	,981
	Treće	2	2,50	2	1,95	,377
	Četvrto	2	2	2	1,23	,540
Korištenje funkcija programa FILE	Prvo	1	,50	1	0,96	,619
	Drugo	1	,50	1	1,52	,469
	Treće	1	1,00	1	1,77	,412
	Četvrto	1	,50	1	1,14	,567

<sup>59</sup> Mjera 'planiranje rada na zadatku' je kategorijalna varijabla, ali se uvjetno može smatrati ordinalnom ljestvicom, jer manji rezultat označava višu razinu plana (1= opći plan, 2= djelomična organizacija, 3=lokalno ulančavanje, 4=bez plana). Ovdje je stoga korišten prosječan rang te mjere.

Rezultati testiranja razlika između klastera u planiranju rada na zadatku i korištenju funkcija programa FILE pokazuju da između različitih motivacijskih profila učenika nema statistički značajnih razlika u korištenju metakognitivnih vještina planiranja i praćenja rada na zadatku.

*Stjecanje znanja o odnosima između varijabli u modelu zadatka*

U tablici 46 prikazane su centralne vrijednosti prosječne pogreške predviđanja rezultata eksperimenata i točnosti teorija učenika o učincima čimbenika na uništenje šuma koje su ostvarili učenici koji pripadaju različitim klasterima, te rezultati testiranja razlika između njih.

*Tablica 46*

Centralne vrijednosti prosječne pogreške predviđanja rezultata eksperimenata i točnosti teorija o učincima čimbenika na uništenje šuma kod učenika koji pripadaju različitim klasterima, te rezultati testiranja statističke značajnosti razlika između klastera

Mjerenje		Klaster 1	Klaster 2	Klaster 3	H (2)	p
		+	-	+		
Prosječna pogreška predviđanja rezultata eksperimenata	Prvo	0,73	0,70	0,68	0,19	,910
	Drugo	0,44	0,47	0,47	0,18	,913
	Treće	0,38	0,28	0,38	1,78	,412
	Četvrto	0,36	0,21	0,40	1,56	,459
Točnost teorija učenika o učinku čimbenika na uništenje šuma	Prvo	5	6,50	5	1,69	,430
	Drugo	7	6,50	7	0,14	,933
	Treće	8	7,50	7,50	0,57	,751
	Četvrto	8	8,50	8	0,75	,689

Učenici različitih motivacijskih profila ne razlikuju se statistički značajno po prosječnoj pogrešci predviđanja rezultata eksperimenata i po razumijevanju odnosa nezavisnih i zavisne varijable postavljenih u modelu zadatka niti u jednom mjerenju.

**5.5.5. Motivacija, metakognitivni doživljaj i istraživačko učenje: integracija rezultata i rasprava**

Ovo poglavlje je pokušalo odgovoriti na treće istraživačko pitanje: *Razlikuju li se, i na koji način, različiti motivacijski profili učenika u procesima učenja i učinku na zadatku istraživačkog učenja?*

Prije rasprave o dobivenim nalazima potrebno je ukratko podsjetiti na ideje koje su vodile formuliranje ovog istraživačkog problema i na racionalu pristupa koji je korišten za odgovaranje na problem.

Već je u uvodnim poglavljima istaknuto da u istraživačkom učenju, koje je samoregulirajuće učenje, ne sudjeluju samo kognitivni procesi, nego i metakognitivni, motivacijski i emocionalni procesi. Važnost tih procesa proizlazi upravo iz samoregulirajuće prirode istraživačkog učenja; učenje se ne odvija pod neposrednom kontrolom istraživačice, već je, iako strukturirano prirodnom zadatka i pitanjima koja postavlja istraživačica, izrazito ovisno o onome što učenik odabire činiti tijekom rada na zadatku. Učenik sam određuje koje će pristupe i strategije koristiti za rad na zadatku i koliko će marljivo i ustrajno raditi. Dakako, o korištenim strategijama rada na zadatku ovisi koliko će učenik uspješno stjecati znanje o odnosima između varijabli. Uspješno rješavanje zadatka zahtijeva korištenje sustavnog i analitičkog pristupa u eksperimentiranju i interpretiranju prikupljenih nalaza. Korištenje takvog pristupa je znatno napornije i zahtjevnije od nesustavnog i brzog pristupa pokušaja i pogrešaka, jer traži značajno veću kognitivnu angažiranost i dublje procesiranje (Rheinberg i sur., 2000, 2002). Valjano zaključivanje uključuje namjernu i planiranu konstrukciju eksperimenata, izvođenje prikladnih eksperimenata koji se mogu međusobno usporediti i analiziranje obrazaca prikupljenih nalaza, pa kao takvo zahtijeva reflektivno i analitičko procesiranje (Kuhn i Pease, 2010). S druge strane, nevaljani zaključci mogu biti doneseni brzo i intuitivno, uz minimalnu razinu procesiranja, koje nije niti kompleksno niti je za njega potrebno uložiti trud. Za nevaljano zaključivanje dovoljno je obratiti pažnju već na jedan slučaj zajedničkog pojavljivanja nekog čimbenika i ishoda, ili vrednovati pomiješane, kovarijacijske podatke, što mogu već i dvogodišnjaci (Kuhn i Pease, 2010).

Budući da korištenje sustavnog i analitičkog pristupa u radu na zadatku istraživačkog učenja zahtijeva višu razinu kognitivnog angažmana i ulaganje truda, pretpostavlja se da se razlike u korištenju istraživačkih pristupa mogu povezati (između ostalog) i s razlikama u motivacijskoj spremnosti učenika za rad na zadatku. Motivacija bi mogla utjecati i na procese i ishode istraživačkog učenja. Motiviraniji učenici bi mogli biti više usredotočeni na ostvarivanje cilja zadatka, ulagati više truda tijekom rada, nastavljati raditi čak i onda kad je ostvaren neki učinak, usmjeravati djelovanje i pažnju na aktivnosti koje su relevantne za postizanje cilja, razvijati planove rada na zadatku i bolje pratiti i kontrolirati rad na zadatku. Motiviraniji učenici bi mogli birati istraživačke pristupe koje odlikuje veći

stupanj sustavnosti i analitičnosti, razvijati valjanije strategije eksperimentiranja i zaključivanja, temeljitije pokrivati prostor eksperimenata i na kraju, stjecati više znanja o kauzalnoj strukturi modela zadatka.

U namjeri istraživanja međuodnosa motivacije i kognitivnih i metakognitivnih procesa tijekom rada na zadatku i ispitivanja navedenih pretpostavki, u radu se pokušalo zahvatiti i simultano mjeriti odvijanje ovih različitih procesa.

Usmjerenost na procese i mikrorazinu rada na jednom zadatku istraživačkog učenja uvjetovala je korištenje situacijski specifičnih motivacijskih mjera i ispitivanje promjena u pojedinim motivacijskim procjenama tijekom rada na zadatku. Motivacija je osmišljena kao skup različitih učeničkih procjena i interpretacija situacije učenja koje mogu imati ulogu u specifičnoj i konkretnoj situaciji učenja. Učenici su procjenjivali vlastiti odnos prema situaciji učenja u trenutku kad se učenje događalo, pa su pri procjenama uzimali u obzir specifične uvjete u kojima se odvijao rad na zadatku, kao i vlastita stanja koja su bila pobuđena radom na zadatku. Iako su upitnikom bile obuhvaćene različite motivacijske varijable (interes za zadatak, samoeфикаsnost, važnost ostvarivanja uspjeha, očekivanje uspjeha), dakako, nisu zastupljeni sve mogući motivacijski koncepti (npr. ciljna orijentacija, intrinzična-ekstrinzična motivacija).

Nadalje, pod pretpostavkom moguće promjenjivosti motivacijskih stanja tijekom rada na zadatku istraživačkog učenja, motivacija je tijekom svakog mjerenja mjerena u više vremenskih točaka - prije početka rada, za vrijeme rada i nakon rada na zadatku. Zbog korištenja specifičnih motivacijskih procjena i ponavljanih mjerenja tijekom rada na zadatku, korištene mjere motivacije mogu se smatrati mjerom aktualizirane, stvarne motivacije učenika u specifičnoj situaciji učenja i određenom trenutku mjerenja.

Usmjerenost na procese koji se događaju u stvarnom vremenu u specifičnoj situaciji učenja uvjetuje da se motivacijske procjene pojavljuju zajedno s emocionalnim reakcijama na zadatak i s metakognitivnim doživljajem. Naime, na razini specifičnosti pojedine situacije učenja i na razini konkretnog zadatka, kod učenika su istovremeno prisutne različite reakcije (doživljaji, iskustva) - različite emocionalne reakcije, metakognitivni osjećaji, metakognitivne procjene zadatka i tijeka procesiranja zadatka, motivacijske procjene zadatka i vlastitog angažmana na njemu. Iako se teorijski radi o ponešto različitim konstruktima, fenomenološki oni čine dio istog, jedinstvenog i ograničenog subjektivnog iskustva učenika u interakciji sa zadatkom i kontekstom u kojem se rad na zadatku odvija,

pa su oni u istraživanju ispitivani simultano i tretirani kao dijelovi cjelovitog doživljaja zadatka. Očekivalo se da su pojedini elementi doživljaja zadatka u određenim (srednje visokim) korelacijama npr. da postoji povezanost između interesa i ulaganja truda, interesa i raspoloženja za rad na zadatku, osjećaja težine i procjene samoefikasnosti, namjere ulaganja truda i važnosti ostvarivanja uspjeha na zadatku itd.

U teorijskim razmatranjima samoregulirajućeg učenja, motivacije i metakognitivnog doživljaja, često je prisutno preklapanje motivacijskih, emocionalnih i metakognitivnih koncepata. Weinert i Kluwe (1987; prema Vollmeyer i Rheinberg, 2005) tvrde da je to preklapanje inherentno definiciji koncepata motivacije i metakognicije. Vollmeyer i Rheinberg (2006) navode da motivacija u različitim modelima samoregulirajućeg učenja pokriva različite motivacijske koncepte - motivacijska vjerovanja (samoefikasnost i očekivanje ishoda), intrinzičnu vrijednost/ interes, ciljnu orijentaciju, ali i percepciju težine zadatka, što se smatra ključnim elementom metakognitivnog doživljaja (iako je slično motivacijskom pojmu 'vjerojatnosti ostvarivanja uspjeha'). Efklides (2006a) navodi da se afektivna iskustva koja se pojavljuju kao reakcija na zadatak (npr. interes za zadatak, sviđanje zadatka) mogu smatrati dijelom metakognitivnog doživljaja, jer se pojavljuju u isto vrijeme kad i metakognitivni osjećaji i procjene. Iako po definiciji ta afektivna iskustva nisu dio metakognicije, ona su usko povezana s percepcijom zadatka i s reakcijama učenika na njega, kao i s vrednovanjem ishoda procesiranja (Efklides, 2002). Konačno, ova autorica metakognitivni doživljaj vidi kao *online* svjesnost učenika koja postoji kad on radi na zadatku, pa uključuje sve što učenik doživljava za vrijeme učenja; i *online* metakognitivno znanje, i različite ideje i vjerovanja i osjećaje, ciljeve i procjene (Efklides, 2001).

U skladu s pomiješanom konceptualizacijom motivacije i metakognitivnog doživljaja, u istraživanjima koja ispituju situacijski specifične motivacijske koncepte, neke varijable koje se smatraju motivacijskima preklapaju se s metakognitivnim mjerama, a neke varijable (npr. procjena težine zadatka ili vrednovanje rezultata učenja) se definiraju i operacionaliziraju na isti način bez obzira predstavljaju li mjere motivacije ili mjere metakognicije (Weinert, 1984, prema Vollmeyer i Rheinberg, 1999). Vollmeyer i Rheinberg u mjeru motivacijskog stanja uključuju procesnu mjeru 'uvjerenost u mogućnost nalaženja pravog rješenja zadatka', koja se uobičajeno mjeri pod oznakom «metakognitivno iskustvo» (Vollmeyer i sur, 1997; Vollmeyer i Rheinberg, 1999, 2000; Rheinberg i sur., 2002). Boekaerts (2002) u svoj upitnik *online* motivacije uključuje i

emocionalne reakcije na zadatak i procjene koje se odnose na namjeru učenja (ulaganje truda). Autorica doduše razlikuje pojedine od tih koncepata, i zasebno ih tretira u analizama interne strukture upitnika (u konfirmatornim faktorskim analizama), međutim, naglašava povezanost specifičnih motivacijskih procjena u specifičnoj situaciji učenja s emocionalnim stanjem pobuđenima zadatkom i ulaganjem truda.

U ovome radu, motivacijski, metakognitivni i emocionalni elementi doživljaja zadatka istraživačkog učenja konceptualno su razdvojeni<sup>60</sup>, ali se u analizi podataka za odgovaranje na treći problem pošlo od ideje cjelovitog subjektivnog iskustva - doživljaja zadatka istraživačkog učenja.

Ispitivanju uloge tog doživljaja zadatka u procesima i ishodima istraživačkog učenja pristupilo se zauzimanjem tzv. *osobi usmjerenog pristupa* (Niemivirta, 2002). Taj pristup, za razliku od *varijablama usmjerenog pristupa* koji je orijentiran na ispitivanje odnosa između varijabli unutar cjelokupne skupine ispitanika, počiva na otkrivanju sličnih (tipova, profila) učenika po nekom skupu varijabli i na analiziranju razlika između tih tipova (profila) na drugim varijablama. U ovom istraživanju korištenjem klaster analize utvrđeni su profili učenika s obzirom na to kako doživljaju zadatak istraživačkog učenja kroz četiri mjerenja. Iako se klaster analiza često kritizira zbog toga što je potpuno deskriptivan, ateoretičan i eksplorativan postupak grupiranja učenika, kao i zbog toga što uvijek rezultira rješenjem, bez obzira ima li ono logičkog ili teorijskog opravdanja (Hair i sur., 2009), ovaj je pristup korišten s očekivanjem da je vjerojatno da učenici ulaze u situaciju istraživačkog učenja s različitim (motivacijskim/ metakognitivnim) orijentacijama koje mogu utjecati na to kako oni pristupaju zadatku i kakve rezultate ostvaruju. Klaster analizom su traženi tipovi učenika kojima se motivacijske, emocionalne i metakognitivne procjene različito razvijaju u situaciji istraživačkog učenja kroz četiri mjerenja, pod pretpostavkom da razmatranje razlika između tih različitih tipova učenika može pomoći u razumijevanju učinaka koje ti procesi imaju na istraživačko učenje.

Osim što korištenje *osobi usmjerenog pristupa* ima svoje opravdanje u pretpostavci o postojanju skupina učenika koji na različite načine reagiraju na istraživački zadatak, ono je dijelom bilo uvjetovano i prirodom prikupljenih podataka i veličinom uzorka koja je

---

<sup>60</sup> Problematičnom se pokazuje npr. mjera 'očekivanje uspjeha', jer se može tretirati i kao motivacijska i metakognitivna varijabla. Ovdje je odlučeno svrstati je u motivaciju (zbog njezinog konvencionalnog uvrštavanja u motivacijske koncepte), međutim, može se tvrditi da je učenički odgovor na pitanje "Kakav uspjeh očekuješ?" produkt neposrednog metakognitivnog praćenja istraživačke aktivnosti, posebice u kasnijim mjerenjima.



onemogućila korištenje regresijskih analitičkih postupaka. Jasno je, međutim, da korištenje eksplorativnih postupaka klaster analize omogućuje deskripciju profila učenika koji pokazuju različite obrasce doživljaja zadatka tijekom rada na njemu, ali ne može dati odgovore o uzročno-posljedičnim odnosima motivacijskih, metakognitivnih i kognitivnih procesa istraživačkog učenja.

Prihvaćeno klustersko rješenje razlikovalo je tri profila učenika s obzirom na njihov doživljaj zadatka istraživačkog učenja. Interpretacija ovih profila temeljila se prije svega na analizi razlika između klastera na varijablama koje su korištene u analizi, ali i na nepostojanju razlika u nekim vanjskim varijablama (npr. u kognitivnim sposobnostima, školskom uspjehu i interesu za znanost). Temeljne razlike između klastera u dvoklusterskom rješenju (koje razlikuje klaster 3 od klastera 1 i 2) nalazile su se u korištenim motivacijskim mjerama, a u troklusterskom rješenju se dodatno razlikovanje (ono između klastera 1 i 2) postiglo pomoću mjera emocionalnog stanja. Imajući u vidu ove razlike, dobiveni su klasteri imenovani i interpretirani kao različiti motivacijski profili učenika<sup>61</sup>.

Utvrđeno je da se različiti motivacijski profili učenika ne razlikuju po istraživačkim pristupima i rezultatima istraživačkog učenja. Motivacija s kojom učenici ulaze u situacije rada na zadatku određuje njihovo motivacijsko stanje tijekom rada; učenici pozitivnije motivacijske orijentacije pozitivnije doživljaju zadatak i vlastito sudjelovanje u radu od učenika negativnije motivacijske orijentacije. Međutim, tri različita motivacijska profila provode podjednak broj eksperimenata u pojedinim mjerenjima, podjednako planiraju eksperimente, podjednako su orijentirani na analizu učinka pojedinih čimbenika, mijenjaju u prosjeku podjednak broj čimbenika po eksperimentu, donose u prosjeku podjednak broj (valjanih) jednostavnih zaključaka i stječu podjednako znanje o kauzalnoj strukturi modela zadatka. Iako se učenici različitih motivacijskih profila razlikuju u doživljaju situacija istraživačkog učenja (prisutan je različit emocionalni ton i doživljaj uspjeha), ne potvrđuju se da (motivacijski, metakognitivni) doživljaj zadatka utječe na učenički pristup radu i na rezultate učenja. Pretpostavka o djelovanju motivacije na procese i ishode istraživačkog učenja ne potvrđuje se, usprkos tome što je operacionalizirana situacijski specifično i što je mjerena u trenutku odvijanja procesa učenja.

---

<sup>61</sup> Korištenje izraza 'motivacijski profili' ne zanemaruje činjenicu da su profili temeljeni na cjelokupnom doživljaju istraživačkog učenja, koji osim motivacijskih, uključuje i emocionalne i metakognitivne mjere. Izraz 'motivacijski profili' naglašava da se profili jasno razlikuju u motivacijskim mjerama, a korišten je radi pojednostavljenja interpretacije rezultata.

Ovi nalazi razlikuju se od nalaza serije istraživanja koje su od kraja '90-tih do danas proveli Rheinberg i Vollmeyer (Vollmeyer i sur., 1997; Vollmeyer i Rheinberg, 1999, 2000, 2006; Rheinber i sur., 2000, 2002), koja su pokazala da motivacijski čimbenici imaju utjecaj na to kako učenici pristupaju istraživačkom učenju i kakav učinak ostvaruju. Ta istraživanja koja su uglavnom koristila analizu traga potvrdila su postavke kognitivno-motivacijskog procesnog modela, prema kojem početna motivacija utječe na ishode istraživačkog učenja preko posredujućeg utjecaja procesnih varijabli kakve su sustavnost rada na zadatku i motivacijsko stanje tijekom učenja. U istraživanjima ovih autora sustavno se pokazuje da početna motivacija djeluje na motivacijsko stanje tijekom učenja i na zauzimanje sustavnog pristupa pri radu na zadatku, a da te varijable utječu na stjecanje i primjenu znanja o modelu zadatka. U nekim istraživanjima, Rheinberg i Vollmeyer su, uz korištenje prediktivnih modela, koristili i drugačiji pristup, koji se može okarakterizirati kao *osobi usmjeren pristup* izučavanja utjecaja motivacije. Primjerice, u jednom istraživanju (Vollmeyer i Rheinberg, 2004, prema Vollmeyer i Rheinberg, 2006) provedena je klaster analiza na temelju faktora početne motivacije, a dobiveni motivacijski profili (skupine 'visoka motivacija', 'niska motivacija' i 'visoka anksioznost') razlikovali su se po učinku na zadatku. U drugom istraživanju (Rheinberg i sur., 2002) formirani su klasteri različitih obrazaca samoregulirajućeg učenja na temelju ponavljanih procesnih mjera (motivacijskog stanja, sustavnosti rada na zadatku i stečenog znanja o modelu) tijekom učenja. I ovo je istraživanje pokazalo da se klasteri koji se međusobno razlikuju po odnosima početne motivacije, kognitivnih sposobnosti i procesnih varijabli razlikuju po učinku istraživačkog učenja.

Postavlja se pitanje: Zašto se različiti motivacijski profili učenika u našem istraživanju ne razlikuju u procesima i ishodima učenja?

Nekoliko je mogućih objašnjenja ovih nalaza.

Kao prvo, motivacijske procjene, kao i procjene emocionalnog stanja i metakognitivnog doživljaja zadatka na kojima se temelji profiliranje učenika pokazuju ograničen varijabilitet u sva četiri mjerenja. Većina ispitanika daje pozitivne procjene, pa se one kreću u ograničenim rasponima pozitivnih dijelova ljestvica. Iako klaster analiza formira klasterne po principu sličnosti procjena (analiza uvijek rezultira klasterima, bez obzira na prirodu ulaznih podataka!), mali varijabilitet procjena praktički znači da razlike između motivacijskih profila nisu velike, odnosno da se niti jedan klaster ne može okarakterizirati kao skupina nemotiviranih učenika. Ta činjenica o klasterima koji se međusobno razlikuju

samo u stupnju pozitivnosti motivacijskih orijentacija, čini eventualne razlike u istraživačkim pristupima i učinku na zadatku manje izvjesnima.

Kao drugo, teorijske konceptualizacije samoregulirajućeg učenja, kakvo je istraživačko učenje u FILE-u, postuliraju interakcije motivacijskih, kognitivnih i metakognitivnih procesa odgovornima za rezultate učenja, umjesto da učinak na zadacima istraživačkog učenja tumače jednostavnim djelovanjem pojedinih procesa. Teško je očekivati razlike u učincima učenika različite motivacijske orijentacije, ukoliko se u obzir ne uzmu razlike između njih u kognitivnim sposobnostima, strateškoj osposobljenosti za svladavanje zahtjeva zadatka, kao i u metakognitivnim kapacitetima za praćenje i reguliranje strateškog djelovanja. Motivacijski utjecaji mogu doći do izražaja onda kad su učenici izjednačeni po drugim relevantnim procesima, dok su u slučaju njihovog nekontroliranja maskirani upravo utjecajem tih drugih procesa. U istraživanjima Vollmeyer i Rheinberga, primjerice, pokušalo se ujednačiti učenike po pristupa radu na zadatku tako što im je prije početka rada na istraživačkom zadatku objašnjeno da je optimalna strategija rješavanja zadatka varirati jednu nezavisnu varijablu u jednom trenutku. Autori taj postupak uvođenja poučavanja o tome kako koristiti sustavan pristup u radu na zadatku opisuju kao postupak reduciranja varijabiliteta u postignućima učenika (Vollmeyer i sur., 1997, Vollmeyer i Rheinberg, 1999, 2000). Iako je ovakav postupak opravdan s pozicija ispitivanja učinka motivacije kao odgovornog čimbenika za razlike u procesima i ishodima istraživačkog učenja između pojedinih učenika, u ovom istraživanju koje, uz motivacijske, ispituje i strateške i metastrateške sastavnice istraživačkog učenja, takav postupak nije opravdan.

U ovom je istraživanju pitanje međuodnosa motivacijskih, metakognitivnih i kognitivnih procesa istraživačkog učenja stoga zahvaćeno pomoću kvalitativne analize procesa učenja kod učenika koji se međusobno razlikuju po motivacijskom orijentaciji i strateškoj izvedbi na zadatku istraživačkog učenja. Suprotstavljeni su slučajevi učenika pozitivnije i negativnije motivacije koji pokazuju nisku stratešku uspješnost na zadatku, koji napreduju u strateškoj izvedbi, i koji već od početka rada na zadatku ostvaruju visoku razinu strateškog djelovanja. Dubinskom analizom procesa učenja unutar i između pojedinih situacija učenja kod ovih slučajeva otvara se mogućnost utvrđivanja različitih motivacijskih utjecaja na procese i rezultate istraživačkog učenja, kao i mogućnost analiziranja promjena u opaženim međuodnosima ovih procesa unutar pojedinih slučajeva između pojedinih mjerenja. Navedena je kvalitativna analiza prikazana u sljedećem poglavlju.

Kao treće, na neutvrđivanje razlika između različitih motivacijskih profila učenika u rezultatima istraživačkog učenja, mogao je utjecati još jedan element istraživačke procedure, onaj koji se odnosi na zahtjev za provedbom minimalnog broja eksperimenata u pojedinom mjerenju. Iako je načelno učenicima bilo omogućeno završiti učenje u trenu kad su to sami željeli, učenici su potaknuti na provedbu minimalno 10 eksperimenata, u slučaju kad su spontano željeli rad završiti ranije. Takav je zahtjev uveden, zato što je, metodološki gledano, prerano prekidanje učenja neprihvatljivo zbog stavljanja učenika u izrazito neusporedive situacije (Vollmeyer i Rheinberg, 2005).

Međutim, imajući na umu često utvrđeni nalaz u psihologiji motivacije o povezanosti motivacije i trajanja učenja (Vollmeyer i sur., 1997; Vollmeyer i Rheinberg, 2000), moguće je da je takav zahtjev na «umjetan» način ujednačio učenje manje i više motiviranih učenika. Nalazi istraživanja, međutim, pokazuju da se različiti motivacijski profili učenika međusobno nisu razlikovali po spontanom broju provedenih eksperimenata, što onda umanjuje značaj ove intervencije kao objašnjenja nepostojanja razlika između profila u procesima i ishodima istraživačkog učenja.

Na kraju, može se pretpostaviti da je neutvrđivanje razlika između različitih motivacijskih profila učenika u procesima i ishodima istraživačkog učenja očekivan nalaz u uvjetima odvijanja istraživačkog učenja bez povratne informacije o učinku učenika na zadatku, odnosno bez informacije o tome koliko uspješno oni stječu znanje o kauzalnom modelu i koliko napreduju u valjanosti zaključivanja o odnosima između varijabli. Naime, u takvim uvjetima, u kojima je učenički doživljaj istraživačkog zadatka temeljen prvenstveno na njihovim motivacijskim dispozicijama i metakognitivnom znanju o sebi i zadatku, ali i na ograničenom neposrednom metakognitivnom praćenju rada na zadatku (koje je ograničeno upravo činjenicom da jedine povratne informacije u zadatku nastaju kao rezultat vlastitog djelovanja), može se očekivati da će razlike između motivacijskih, metakognitivnih i emocionalnih procjena učenika koji pripadaju različitim profilima biti relativno stabilne u vremenu, te da će te procjene biti malo povezane s istraživačkim pristupima i rezultatima koje učenici ostvaruju na zadatku. Npr. niski osjećaj težine zadatka i visok osjećaj samoefikasnosti može biti prisutan i kod učenika koji nesustavno rade na zadatku i donose nevaljane zaključke o odnosima između varijabli i kod učenika koji sustavno variraju čimbenike i donose valjane zaključke, zato što rad na zadatku ne pruža jasne informacije koje mogu pomoći učenicima u procjeni stečenog znanja i u određivanju, prilagođavanju i korigiranju vlastitih metakognitivnih i motivacijskih procjena. S druge strane, u situaciji u

kojoj bi rad na zadatku istraživačkog učenja bio popraćen informacijama o postignućima učenika, moguće je očekivati da bi takva informacija mogla utjecati i na pristup koji učenici zauzimaju u radu i na motivacijsko stanje koje prati rad na zadatku (jer bi učenici mogli temeljiti svoje motivacijske procjene na tim informacijama), te doprinijeti njihovoj većoj povezanosti.

Stabilnosti motivacijskih, emocionalnih i metakognitivnih procjena vjerojatno doprinosi i ponavljano ispitivanje istih mjera u različitim mjerenjima (prije rada na zadatku, tijekom rada i nakon rada). Naime, ponovljeno ispitivanje istih pitanja izaziva osjećaj dosade kod učenika, pa oni pokazuju tendenciju davanja istih odgovora, unatoč mogućnosti da je u njihovom radu ili doživljaju zadatka možda došlo do nekih promjena. Kao posljedica toga, učeničke motivacijske procjene malo variraju i nisu povezane s učenjem. Do sličnih uvida dolaze Vollmeyer i Rheinberg koji navode da učenici reagiraju s neodobravanjem na zahtjev ponovnog odgovaranja na ista pitanja, posebice onda kad su imali dojam da se tijekom rada na zadatku ništa nije promijenilo, što je za posljedicu imalo manji varijabilitet u mjerama motivacijskog stanja tijekom rada na zadatku nego u mjerama početne motivacije (Vollmeyer i Rheinberg, 2003, prema Vollmeyer i Rheinberg, 2006).

## **II. DIO: ANALIZA PROCESA ISTRAŽIVAČKOG UČENJA TIJEKOM RADA NA ZADATKU: KVALITATIVNA ANALIZA SLUČAJEVA**

Kvantitativne analize podataka, prikazane u prethodnim poglavljima, omogućile su analizu promjena u kognitivnim, metakognitivnim i motivacijskim elementima istraživačkog učenja između pojedinih mjerenja te pružile uvid u međusobnu povezanost tih procesa na razini pojedinih mjerenja. Također, provedene su analize ukazale na nepostojanje statistički značajnih razlika između učenika različitih motivacijskih profila u procesima i ishodima istraživačkog učenja, u slučaju kad su pojedina mjerenja uzimana kao jedinice analize. Jasno je, međutim, da korišteni analitički pristup, koji počiva na prosječnim vrijednostima i sažimanju podataka iz pojedinih eksperimenata za svakog ispitanika, ne uspijeva dubinski zahvatiti sam proces učenja i opisati suptilne intra- i interindividualne razlike u istraživačkom pristupu koji zauzimaju različiti ispitanici unutar pojedinih mjerenja. Imajući na umu da bi se ograničavanjem istraživanja samo na kvantitativne analize na razini pojedinih mjerenja riskiralo pretjerano pojednostavnjivanje mjerenih pojava i svođenje složenog procesa istraživačkog učenja na skup ograničenih mjera, u radu je provedena i kvalitativna studija slučajeva (učenika).

Uključivanje dubinske analize procesa istraživačkog učenja kod određenih učenika značajno upotpunjuje odgovore na postavljena istraživačka pitanja, omogućuje bogatiju deskripciju i bolje razumijevanje analiziranih procesa, pa doprinosi cjelovitijem sagledavanju kompleksnosti istraživačkog učenja i potpunijem objašnjenju međuodnosa kognitivnih, metakognitivnih i motivacijskih procesa tijekom rada na istraživačkom zadatku.

Studija slučajeva je započela izborom slučajeva za dubinsku analizu, te određivanjem kvalitativnog analitičkog okvira. Te su procedure opisane u nastavku.

## 5.6. Odabir slučajeva za kvalitativnu analizu

Odabir učenika za dubinsku analizu procesa učenja proveden je korištenjem pristupa teorijskog uzorkovanja (Patton, 1990), odnosno uvažavanjem principa maksimalizacije moguće spoznaje na temelju proučavanja određenih slučajeva (Yin, 1994; Stake, 1995).

Budući da je uzorkovanje provedeno u trenutku kad je kvantitativna analiza podataka već bila završena, rezultati tih analiza su, uz razmatranje teorijskih propozicija unutar kojih je istraživanje provedeno, predstavljali glavno polazište za određivanje kriterija izbora slučajeva. Kao prvi kriterij uzorkovanja korišteno je profiliranje učenika prema prospektivnim motivacijskim i emocionalnim procjenama i metakognitivnom doživljaju zadatka tijekom četiri mjerenja. Pritom, ovdje je za podjelu učenika u skupine korišteno dvoklastersko rješenje (umjesto troklasterskog)<sup>62</sup>. Tako su razlikovane skupine učenika pozitivnije i negativnije motivacijske orijentacije, a svaka je u kvalitativnoj analizi reprezentirana s tri slučaja.

Drugi kriterij uzorkovanja učenika za studiju slučajeva predstavljala je podjela učenika s obzirom na uspješnost njihove strateške izvedbe na zadatku kroz četiri mjerenja (vidi tablicu 12 u Prilogu). Analizom individualnih putova razvoja valjanosti jednostavnog zaključivanja o odnosima između varijabli ustanovljena je mogućnost razlikovanja tri skupine učenika kao osnove za izbor slučajeva. Prvu skupinu činili su učenici koji tijekom cjelokupnog rada na zadatku istraživačkog učenja ne uspijevaju postići zadovoljavajuću razinu valjanog zaključivanja, pa do kraja istraživanja ne ostvaruju strateški uspjeh i ne postižu više od 50% valjanih jednostavnih zaključaka. Drugu skupinu činili su učenici koji na početku istraživačkog učenja, posebice u prvom mjerenju, ostvaruju nisku valjanost zaključivanja, ali do kraja rada na zadatku napreduju do razine koja se smatra strateškim uspjehom. Treću skupinu su činili učenici koji već na početku rada na zadatku postižu visok postotak valjanih zaključaka, i više-manje stabilno zadržavaju tu visoku razinu postignuća kroz cijelo trajanje istraživanja.

Unutar skupina učenika pozitivnijeg i negativnijeg motivacijskog profila, odabran je po jedan učenik za svaku skupinu formiranu s obzirom na razinu strateške izvedbe na

---

<sup>62</sup> Učenici koji su pripadali klasteru 1 i 2 (++) i (--) povezani su u jednu skupinu prema rezultatima klaster analize. Spajanje klastera je provedeno zbog malog broja učenika u klasteru 2 i nepostojanja slučajeva unutar pojedinih kategorija prema drugom kriteriju uzorkovanja.

zadatku<sup>63</sup>. Tako je izabrano ukupno šest slučajeva koji reprezentiraju različite odnose motivacijske orijentacije i strateške uspješnosti na zadatku.

Opisanim postupkom uzorkovanja slučajeva za dublju analizu procesa istraživačkog učenja osigurano je da odabrani učenici zahvaćaju varijabilitet u iskustvu i izvedbi koji je opažen u ukupnom uzorku učenika, a ujedno predstavljaju ilustrativne slučajeve koji omogućuju suprotstavljanje i uspoređivanje procesa učenja kod učenika različite motivacijske orijentacije za rad na zadatku, kao i učenika koji se međusobno razlikuju po učinku u istraživačkom učenju. Time je osiguran izbor slučajeva koji najbolje mogu ukazati na kritične točke proizašle iz prethodnih analiza i osvijetlili neke nove momente koje nije bilo moguće uočiti kroz kvantitativne analize.

U tablici 47 opisani su odabrani slučajevi s obzirom na kriterije uzorkovanja.

*Tablica 47*

Izabrani slučajevi za kvalitativnu analizu procesa učenja (u ćelijama je prikazan postotak valjanih jednostavnih zaključaka od prvog do četvrtog mjerenja)

	Ne ostvaruje strateški uspjeh do kraja rada na zadatku	Ostvaruje napredak prema strateškom uspjehu	Već na početku rada ostvaruje strateški uspjeh
Pozitivnija motivacijska orijentacija (klaster 3)	<b>Oliver</b> 6 - 18 - 14 - 15	<b>Dea</b> 0 - 18 - 100 - 100	<b>Iva</b> 55 - 58 - 83 - 94
Negativnija motivacijska orijentacija (klaster 1 + 2)	<b>Lena</b> 0 - 17 - 38 - 38	<b>Marin</b> 0 - 24 - 17 - 67	<b>Borna</b> 86 - 100 - 73 - 89

## 5.7. Razvoj kvalitativnog analitičkog okvira (kodne sheme)

U opisu i analizi procesa istraživačkog učenja kod izabranih slučajeva korišteni su svi podaci prikupljeni za potrebe kvantitativnih analiza, ali su oni upotpunjeni dodatnim analizama verbalnih protokola i opažanjima učeničkog ponašanja tijekom rada na zadatku na video snimkama. Na taj način, u odnosu na kvantitativnu analizu, dodatno je povećan broj izvora i vrsta podataka te omogućena triangulacija prikupljenih podataka.

<sup>63</sup> Odabir slučajeva je napravljen tako da se omogući deskripcija procesa učenja i osigura komparacija pojedinih kategorija učenika. Treba istaknuti da izabrani slučajevi, dakako, nisu izabrani kao reprezentativan uzorak svih učenika. To znači da oni ne omogućuju statističku generalizaciju, već analitičku generalizaciju povezanu s teorijskim propozicijama (Yin, 1994). Već usporedba učenika po kriteriju strateške uspješnosti unutar skupina različitih motivacijskih profila pokazuje da u skupini učenika negativnije motivacijske orijentacije koju čini 19 ispitanika, najveći broj njih ostvaruje napredak prema strateškom uspjehu (10 učenika), a znatan broj pokazuje visok stupanj valjanog zaključivanja već u prvom mjerenju (6 učenika), dok u skupini pozitivnije motivacijske orijentacije koju čini 14 ispitanika, visoku početnu razinu strateške izvedbe iskazuje tek 3 ispitanika, a jasan napredak ostvaruje 4 ispitanika.



Transkribirani verbalni protokoli su korišteni kao izvor informacija o spontanom korištenju metakognitivnih aktivnosti, te o motivacijskim i emocionalnim reakcijama učenika tijekom rada na zadatku, dok je opažanje učeničkih ponašanja bilo usmjereno na bilježenje neverbalnih izraza motivacijske spremnosti i raspoloženja za rad na zadatku.

Pri analizi verbalnih protokola s obzirom na pojavljivanje i vrste metakognitivne aktivnosti, vodilo se računa da se postojanje metakognitivnih aktivnosti bilježi neovisno o procjeni kvalitete informacija do kojih te aktivnosti donose. Primjerice, neovisno o tome jesu li objašnjenja koja učenik daje točna ili netočna, utvrđeno je koliko ih učenik daje i koliko su ona elaborirana. Ili, bilježilo se postojanje plana aktivnosti, iako ishodi primjene plana ne moraju biti pozitivni. Takvim se pristupom izbjegava preklapanje mjera metakognitivnih vještina s mjerama strateškog uspjeha na zadatku.

Za kodiranje metakognitivnih i motivacijskih aspekata istraživačkog učenja i kvalitativnu analizu tih ponašanja razvijene su zasebne kodne sheme. Kodna shema kvalitete metakognitivnih vještina, prikazana u tablici 48, zasnovana je na temelju kriterija koje su razradili Veenman i Elshout (npr. Veenman i sur., 1997, 2002; Prins i sur., 2006), ali je doradena na temelju opažanja konkretnih situacija učenja u ovome istraživanju, dodavanjem nekih kodova koji su označavali postojanje nekih za zadatak specifičnih metakognitivnih aktivnosti.

*Tablica 48*

Kodna shema za analizu korištenja metakognitivnih vještina tijekom procesa istraživačkog učenja

<b>Kôd više razine</b>	<b>Opis ponašanja učenika</b>
Orijentacija i planiranje (priprema za provedbu zadatka)	Analiza zahtjeva zadatka/ provjera razumijevanja zahtjeva zadatka/ parafraziranje zahtjeva zadatka, aktiviranje prijašnjih znanja, planiranje aktivnosti prije njihovog izvršavanja, elaboracija očekivanja prije provedbe eksperimenata, odabir strategije rješavanja zadatka
Sustavnost u radu	Planiranje slijeda eksperimenata tijekom rada, slijeđenje plana, rad „po redu“, izbjegavanje nesustavnog provođenja eksperimenata
Praćenje i regulacija rada na zadatku	Praćenje izvedbe planiranih aktivnosti/ provjera ispravnosti provedbe eksperimenata i zaključivanja, procjena učenja (učenik je svjestan da ne razumije sve odnose varijabli), vraćanje na već napravljene eksperimente, otkrivanje i korekcija pogrešaka, otkrivanje i provjera neobičnih rezultata, identificiranje i ponavljanje važnih podataka (koje treba zapamtiti), svjesno mijenjanje strategija rada na zadatku, objašnjavanje i opravdavanje uporabe strategija, praćenje približavanja cilju rada na zadatku, komentiranje zahtjeva zadatka i dostupnog vremena (koliko još treba napraviti)
Elaboracija i refleksija	Povezivanje rezultata različitih eksperimenata, sumiranje postignutih rezultata, pohranjivanje ishoda eksperimenata u pamćenju, rekapitulacija i refleksija s obzirom na cilj zadatka (potvrđivanje toga daju li doneseni zaključci odgovore na pitanja o odnosima varijabli)

Iz tablice 48 se može uočiti da glavne kategorije kodova uglavnom odgovaraju fazama koje opisuju različiti modeli samoregulirajućeg učenja (npr. Schunk i Zimmerman, 1998; Pintrich, 2004; Winne i Perry, 2005).

Pri izradi kodne sheme za analizu motivacijskih i emocionalnih procesa tijekom istraživačkog učenja uzeta su u obzir teorijska razmatranja i konstrukti koji su već bili uključeni u istraživanje kroz upitničke mjere i kvantitativne analize podataka. Međutim, kodna shema je u konačnici razvijena induktivnim postupkom, na temelju kvalitativnih opažanja i uvida istraživačice stečenih tijekom procesa prikupljanja podataka, te na temelju pregleda snimljenih materijala i pripremljenih transkripata. Prikaz te kodne sheme se nalazi u tablici 49.

*Tablica 49*

Kodna shema za analizu motivacijskih i emocionalnih procesa tijekom istraživačkog učenja

<p><b>Pozitivna verbalna ekspresija</b> Interes za zadatak, spremnost za ulaganje truda, osjećaj osobne kompetentnosti za rješavanje zadatka, pozitivne atribucije</p>	<p><b>Negativna verbalna ekspresija</b> Nezanimanje za zadatak, namjera prekida rada/ završavanja rada, zbunjenost, dosada, frustriranost</p>
<p><b>Pozitivna neverbalna ekspresija</b> Usredotočenost na zadatak, zainteresiran i opušten izraz lica i položaj tijela, osmjehivanje</p>	<p><b>Negativna neverbalna ekspresija</b> Nezainteresiran izraz lica i položaj tijela, napet izraz lica i položaj tijela, uzvici</p>

Na temelju opažanja rada učenika na zadatku istraživačkog učenja i verbalnih protokola, zabilježeno je svako pojavljivanje navedenih ponašanja učenika, kao i raspored njihovog pojavljivanja unutar pojedine situacije učenja.

Na jednak način, prema postupcima opisanima u metodološkom poglavlju, zabilježeno je korištenje istraživačkih vještina i strategija tijekom provedbe pojedinih eksperimenata, a svi navedeni podaci činili su osnovu za kvalitativnu analizu pojedinih slučajeva. Dakako, ta je analiza, za razliku od provedene kvantitativne analize, bila usmjerena na razinu pojedinih eksperimenata i njihovog slijeda unutar pojedinih mjerenja.

Na temelju svih prikupljenih podataka, za svakog je ispitanika napravljen deskriptivan prikaz procesa učenja u pojedinim mjerenjima, te je provedena interpretacija temeljem međusobne usporedbe slučajeva i usporedbe dobivenih nalaza za pojedini slučaj s teorijskim očekivanjima. Prikaz rezultata kvalitativne analize procesa učenja, koji slijedi u nastavku poglavlja, prati postavljeni analitički okvir, pa sumira nalaze o procesu učenja kroz usporedbu pojedinih slučajeva.

## 5.8. Rezultati kvalitativne analize procesa istraživačkog učenja

Kao što je opisano u prethodnom poglavlju, za kvalitativnu analizu procesa istraživačkog učenja izabrano je šest učenika koje karakteriziraju različite kombinacije motivacijskih i kognitivnih sastavnica tog procesa. Takvim izborom slučajeva, uz čistu deskripciju ispitivanih procesa na razini pojedinih eksperimenata kod učenika koji reprezentiraju različite dijelove učeničke populacije, pružena je mogućnost stjecanja cjelovitijih i dubljih uvida u međudnose motivacijskih, kognitivnih i metakognitivnih procesa tijekom rada na zadatku.

Na početku prikaza rezultata, radi boljeg upoznavanja izabranih slučajeva, u tablici 50 dat je opis nekih poznatih obilježja tih učenika.

*Tablica 50*  
Deskriptivni podaci o izabranim slučajevima

	<b>Lena</b>	<b>Oliver</b>	<b>Marin</b>	<b>Dea</b>	<b>Borna</b>	<b>Iva</b>
Motivacijska orijentacija	-	+	-	+	-	+
Strateška izvedba na zadatku	niska	niska	napredak	napredak	visoka	visoka
Interes za znanost	ispod-prosječan	ispod-prosječan	ispod-prosječan	iznad-prosječan	ispod-prosječan	iznad-prosječan
Interes za temu "Onečišćenje i očuvanje šuma, mora, zraka i tla"	malen	srednji	malen	velik	malen	velik
Rezultat na Testu nizova	iznad-prosječan	ispod-prosječan	ispod-prosječan	ispod-prosječan	iznad-prosječan	ispod-prosječan
Procjena nastavnika o istraživačkom kapacitetu	srednji	visok	nizak	visok	visok	nizak
Ocjena iz biologije u 7. razredu	4	3	4	5	5	5
Ocjena iz fizike u 7. razredu	5	4	4	5	5	5
Ocjena iz kemije u 7. razredu	4	4	4	4	5	5

U nastavku slijedi detaljan prikaz istraživačkog učenja kod izabranih slučajeva. Potpuni popis eksperimenata koje su ti ispitanici proveli nalazi se u Prilogu, dok se u prikazu rezultata koriste samo nalazi pojedinih mjerenja, koji sadrže neke tipične ili ilustrativne primjere.

U opisu rezultata kvalitativne analize polazi se od prikaza i usporedbe tijeka učenja kod učenika koji postižu različitu razinu strateškog uspjeha na zadatku. Prvi dio analize je posvećen Leni i Oliveru kao predstavnicima učenika koji tijekom cijelog rada na zadatku ne uspijevaju postići zadovoljavajuću razinu valjanosti zaključivanja. Nakon toga, dat je

prikaz učenja Marina i Dee, dakle, učenika koji u četiri situacije učenja pokazuju značajan napredak prema valjanom zaključivanju i visokoj razini strateške izvedbe. Na kraju, prezentiran je istraživački rad Borne i Ive koji su već na početku rada na zadatku postizali više od 50% valjanih jednostavnih zaključaka.

### **5.8.1. Niska razina strateške izvedbe na zadatku (Lena i Oliver)**

#### *Lena*

U istraživanje istraživačkog učenja Lena je uključena kao učenica visokih sposobnosti induktivnog rezoniranja (prema rezultatu Testa nizova) i ispodprosječnog interesa za znanost. Početni interes koji Lena iskazuje za zadatak o uništenju šuma je također malen, (iako njezina procjena zapravo označava srednju vrijednost ljestvice), kao i njezina opća motivacija za sudjelovanje u istraživanju. O tome svjedoči činjenica da je, nakon izbora u uzorak učenika koji će sudjelovati u individualnim ispitivanjima, Lena izrazila želju da ne sudjeluje, ali se poslije (iz nepoznatih razloga) predomislila.

Prije početka rada na zadatku, Lena je zadatak procijenila uglavnom laganim, te je smatrala da je potrebno uložiti osrednji trud u njegovo rješavanje. Takva je procjena vjerojatno bila vezana uz njezinu visoku procjenu samoeфикаsnosti za rješavanje zadatka, ali i uz relativno nisku vrijednost koju je za nju imalo postizanje uspjeha na njemu.

U rješavanje zadatka o uništenju šuma Lena je krenula bez metakognitivnog razumijevanja cilja zadatka kao onog u kojem se traži utvrđivanje učinka svakog pojedinog čimbenika na uništenje šuma. Na pitanje o cilju i strategiji rada na zadatku o Petru koji kasni u školu, ona odgovara *«Na ovom zadatku cilj je dokazati kako je Petar jedno neodgovorno i zbunjeno dijete koje treba razgovorom ukloniti svoje teškoće»* te *«Mislim da bi se morao ranije probuditi, obaviti svoje obveze u miru i na vrijeme krenuti u školu»*.

O nepostojanju analitičke usmjerenosti na utvrđivanje učinaka koje različiti čimbenici imaju na uništenje šuma govori i Lenina konstantna preokupacija eksperimentiranjem koje ima za cilj generiranje pojedinih rezultata eksperimenata. Naime, od prvog do četvrtog mjerenja Lena zauzima tzv. inženjerski pristup i kroz eksperimente koje provodi pokušava dobiti isprva, na primjer, rezultat 5 (najveći stupanj uništenja šuma), pa 1 (najmanji stupanj uništenja), pa onda stupanj 3, pa 4 i 2. Za Leninu je rad karakteristično da provodi eksperimente sve dok ne pokaže svih pet stupnjeva uništenja šuma, pritom ne vodeći previše računa o tome koji čimbenici čine kombinacije koje dovode do pojedinih ishoda.

Tijekom cjelokupnog rada na zadatku Lena nije uobičavala postavljati hipoteze kojima bi izrazila svoja očekivanja o učinku nezavisnih varijabli na uništenje šuma, što je razumljivo s obzirom na to da eksperimente nije niti provodila s ciljem utvrđivanja odnosa između varijabli. Kad bih je pitala što očekuje otkriti u pojedinom eksperimentu, uvijek bi odgovorila u terminima stupnja uništenja šuma (npr. *«To bi moglo biti 3»*), a tek povremeno je obrazlagala svoja očekivanja tako da je ponavljala koje je sličice odabrala i opisivala kakav rezultat eksperimenta očekuje s obzirom na tu cjelokupnu kombinaciju izabranih čimbenika. Na primjer, tijekom prvog mjerenja u četvrtom eksperimentu u kojem je izabrala bjelogoričnu šumu, brežuljkasti pojas, udaljenost od naselja, rijetko padanje kiselih kiša i nametnike, svoje je očekivanje objasnila sljedećim riječima: *«Očekujem srednju zagađenost zato što sad nije ništa pretjerano strašno prisutno. Bjelogorična šuma slabije gori od crnogorične, a i brdoviti teren baš nije pogodan za vatru....Nema blizu niti kuća, tako da je manja vjerojatnost da se nešto zapali.... Nema učinka kiselih kiša. Ali kukci bi mogli utjecati na štetu»*.

Tek u nekoliko slučajeva u kasnijim mjerenjima Lena se primiče postavljanju jasnijih hipoteza o učinku pojedinih čimbenika, ali ni tad nije potpuno eksplicitna u izražavanju svojih očekivanja. U trećem mjerenju je, primjerice, drugi eksperiment postavila tako da dobije minimalni stupanj uništenja kombinacijom crnogorice, nizinskog pojasa, udaljenosti šume od naselja, rijetkog padanja kisele kiše i uklanjanjem nametnika. U sljedećem eksperimentu promijenila je kisele kiše u često padanje, te je dodala nametnike, a ovako je izrazila svoje očekivanje *«To će biti dvojka. Sve sam napravila kao i u prošlom eksperimentu samo sam malo pojačala utjecaj kiselih kiša i stavila kukce, pa bi sad trebalo biti 2»*. Ovakvo formuliranje očekivanja, koje naznačuje očekivani utjecaj određenih čimbenika na uništenje šuma i usmjerava pažnju ispitanice na pojedine čimbenike pružilo joj je mogućnost da sljedeći (četvrti) eksperiment postavi na način koji omogućuje valjano zaključivanje o učinku kiselih kiša. Tome je svakako pridonijela i činjenica da se Lena izrazito iznenadila kad je uvidjela da treći eksperiment umjesto s njezinih očekivanih 2, rezultira s 4. U tom trenutku Lena je začuđeno pogledala u ekran i rekla: *«Uh, kaj?!?! Majko božja! Onda su kukci tako štetni! Kukci jako pridonose tom uništenju!»*. Iako ovaj inkluzivni zaključak nije bio valjan (jer je Lena osim nametnika promijenila i čimbenik kisele kiše u odnosu na prethodni eksperiment), ovakav tijek eksperimentiranja ju je naveo da u sljedećem pokusu valjano varira samo čimbenik kiselih kiša, te donese valjan zaključak o učinku tog čimbenika. Kako i u tom pokusu nije bio potvrđen rezultat koji je

očekivala (umjesto 3, rezultat je bio 2), Lena je komentirala: *«Isuse Bože, sad je dvojka! Ali sad mogu vidjeti da i kisele kiše imaju jako veliki utjecaj!»*. Međutim, nakon donošenja tog valjanog zaključka, Lena ponovno gubi analitički fokus te se vraća na osmišljavanje eksperimenata s ciljem ostvarivanja određenog eksperimentalnog ishoda.

Zanimljivo je da je ovaj zaključak o učinku kiselih kiša, postignut tijekom trećeg mjerenja, bio zapravo prvi potpuno valjani zaključak<sup>64</sup> u kojem je Lena sasvim jasno osvrnula na empirijske nalaze koje je stvorila i donijela zaključak upravo na temelju njih, usporedbom dva pokusa. Takve zaključke Lena nije uopće imala u prvom i drugom mjerenju.

U prvom mjerenju u kojem je provela ukupno 10 eksperimenata, u šest je eksperimenata donijela 13 jednostavnih zaključaka o učinku pojedinih čimbenika na uništenje šuma (od toga 12 inkluzivnih!), dok se u tri eksperimenta uglavnom zadovoljila time da je točno predvidjela rezultate eksperimenata. Međutim, niti jedan od tih donesenih jednostavnih zaključaka nije bio valjan, odnosno nije se temeljio na usporedbi barem dva eksperimenta koji se razlikuju samo po jednoj varijabli. Analiza vrsta zaključaka koje je Lena donijela tijekom prvog mjerenja pokazuje da se njezini nevaljani zaključci ne temelje na nekontroliranoj usporedbi dva eksperimenta, već su dominantno teorijski uvjetovani, temeljeni na jednom eksperimentu ili, pak, generalizirani.

Dio nevaljanih zaključaka koje je Lena donijela tijekom tog prvog mjerenja toliko je bio inspiriran njezinim prethodnim teorijama o učinku pojedinih čimbenika na uništenje šuma da je za nju već pojedini slučaj zajedničkog pojavljivanja određene razine varijable i ishoda eksperimenta bio dovoljan za donošenje zaključka o utjecaju tog čimbenika.

Primjerice, nalazi koje je Lena stvorila u prvom mjerenju, prikazani u okviru 1, pokazuju da je ona u trećem eksperimentu odabrala čimbenike sasvim suprotno od prethodnog pokusa. U tom (trećem) eksperimentu Lena nije izrazila jasnu namjeru ispitivanja, iako je navela da će probati *«vidjeti koliki je stupanj uništenja kod bjelogorice, koja je na ravnom tlu, blizu naselja, uz smanjenje kiselih kiša i bez kukaca»*. Dobiveni rezultat koji se razlikovao od njezinog predviđanja, Lena je interpretirala pomoću svoje teorije o većoj uništenosti crnogorične šume i većoj štetnosti uništavanja te vrste šume. Na temelju zajedničkog pojavljivanja bjelogorične šume i niske razine uništenosti u trećem

---

<sup>64</sup> Tijekom drugog mjerenja u 12. pokusu Lena je donijela inkluzivne zaključke o vrsti šume i nametnicima, koji su kodirani kao valjani zaključci zato što su u nalazima bili prisutni eksperimenti koji omogućuju donošenje tih valjanih zaključaka. Iako je iz Leninog iskaza bilo jasno da zaključak donosi na temelju prikupljenih podataka, nije se eksplicitno u usporedbi osvrnula upravo na te pokuse. Stoga se tek opisani zaključak iz trećeg mjerenja može smatrati pravim valjanim zaključkom.

eksperimentu (ne uzimajući u obzir moguće djelovanje drugih čimbenika), Lena je zaključila: «*Ako gori<sup>65</sup> bjelogorična šuma, onda to nije strašno*».

Dio nevaljanih zaključaka koje je Lena donijela tijekom prvog mjerenja temeljio se na (površnom) razmatranju nalaza iz više eksperimenata, pa se oni mogu smatrati generaliziranim nevaljanim zaključcima. Primjer takvog zaključka vezan je uz četvrti eksperiment. Lena u tome eksperimentu donosi zaključak o utjecaju nametnika na uništenje šuma i daje ovakvo objašnjenje svog inkluzivnog zaključka: «*Ako nema kukaca, onda neće biti toliko uništenja....U svim dosadašnjim pokusima kukci su imali veze, a kad nema kukaca odmah se postotak mogućnosti požara smanjio*».

### Okvir 1

Nalazi koje je Lena stvorila tijekom prvog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
1	1	crnogorica	nizina	blizu	vrlo	ima	4	4
1	2	crnogorica	brijeg	daleko	cesto	ima	2	4
1	3	bjelogorica	nizina	blizu	rijetko	nema	3	1
1	4	bjelogorica	brijeg	daleko	rijetko	ima	2	3
1	5	crnogorica	nizina	blizu	cesto	nema	2	3
1	6	crnogorica	brijeg	blizu	vrlo	ima	5	4
1	7	bjelogorica	brijeg	daleko	vrlo	nema	3	3
1	8	crnogorica	brijeg	daleko	rijetko	ima	2	2
1	9	bjelogorica	nizina	blizu	cesto	nema	3	3
1	10	crnogorica	nizina	blizu	cesto	nema	3	3

Peti eksperiment je Lena postavila opet kao suprotnost prethodnog eksperimenta, te je nevaljano zaključila, zbog dobivenog većeg stupnja uništenja šuma od onog koji je očekivala, da na stupanj uništenja šuma utjecaj ima i vrsta drveće (crnogorično), i više kiselih kiša, i blizina naselja i nizinski teren. Ovaj zaključak može se shvatiti kao potpuno teorijski utemeljen nevaljani zaključak, jer počiva na Leninim objašnjenjima koja ne uzimaju u obzir rezultate eksperimentiranja, već na njenim vjerovanjima o većem uništenju šuma u slučaju šuma koje su crnogorične, blizu naselja, na nizinskom području i u kojima padaju kisele kiše. Ovaj zaključak također govori o često zapaženoj tendenciji ispitanika u ovom, ali i u drugim istraživanjima, da se učinak na zavisnu varijablu pridaje pojedinoj kategoriji unutar nezavisne varijable, a ne 'cijeloj' varijabli (koja ima dvije ili tri

<sup>65</sup> Leni je tijekom rada više puta objašnjeno da se pod uništenjem šuma ne podrazumijeva nužno požar. Njezine su teorije i interpretacija nalaza, međutim, često uništenje šuma izjednačavale s uništenjem šuma od požara.

kategorije). Lena tako kaže: *«Utječu naselja, nizina, više kiselih kiša i crnogorica, naravno!»*.

Osim donošenja svih zaključaka na nevaljani način, Lenino prvo mjerenje karakterizira i mijenjanje vrste zaključaka o nekim čimbenicima. Kad se radi o čimbeniku 'udaljenost šume od naselja', ona donosi inkluzivan zaključak o tom čimbeniku u petom eksperimentu (kad se blizina naselja uparuje sa kiselom kišom kao čimbenikom koji objašnjava postojanje srednjeg stupnja uništenja šume), dok je šesti eksperiment upućuje na donošenje ekskluzivnog zaključka. On doduše nije čvrst, budući da Lena kaže: *«Opet nije najjači stupanj. Uh! Stupanj je četiri, zato što ima učinak kukaca, brdovit je i nepovoljan teren, utjecaj kiselih kiša je vrlo jak, naselje je blizu i drveće je crnogorično.....Ovo naselje baš i nema neki veliki učinak, ovisi.....(puše)....Dosta je ovo ostalo da bude stupanj 4, još i dodatak naselja nije potreban»*. Stoga i ne čudi što se u devetom eksperimentu Lena vraća na inkluzivni zaključak o ovome čimbeniku, koji uostalom i odgovara njezinoj početnoj teoriji o njemu. U ovom slučaju ponovnog donošenja inkluzivnog zaključka, on je utemeljen na eksperimentu s istom kombinacijom čimbenika kao i peti eksperiment, s izuzetkom promijenjene vrste šuma. Blizina naselja (čimbenik za koji Lena vjeruje da je kauzalan) je opet uparena s kiselim kišama (koje su stvarni kauzalni čimbenik), pa je čimbenik 'udaljenost šume od naselja' na takav način stekao iluzoran kauzalni učinak preko kovariranja sa stvarnim kauzalnim čimbenikom.

Lena je tijekom prvog mjerenja promijenila i teoriju o vrsti drveća u šumi. Ovdje, međutim, nije riječ od promjeni iz inkluzivnog u ekskluzivni zaključak (ili obrnuto), već o mijenjanju smjera inkluzivnog zaključka. Dok je, po početnoj teoriji i zaključcima u ranoj fazi prvog mjerenja, Lena povezivala viši stupanj uništenja uz crnogoričnu šumu i obrazlagala ga sljedećim mehanizmom *«Crnogorična šuma više gori i štetnije je kad gori»*, u sedmom eksperimentu dolazi do nagle promjene teorije (zato što je osrednji stupanj uništenja bio prisutan već uz šumu udaljenu od naselja, i uz prisutnost samo jednog od jasnih kauzalnih čimbenika po njezinoj teoriji - ili nametnika ili kiselih kiša) i novog objašnjenja *«Bjelogorično drveće je uvijek malo osjetljivije, zato što gubi lišće....a crnogorično može i više godina izdržati na životu»*. Upitana da objasni govori li joj nešto od provedenih eksperimenata o tome, ona odgovara *«Ne, to općenito govorim! Zato što bjelogorično drveće nije toliko jako kao crnogorično i puno je osjetljivije, i tijekom godina se mogu nakupiti kisele kiše, dok kod crnogoričnih šuma ne ide to baš tako...U pokusima mi se to isto pokazuje, jer kad je u pitanju crnogorično drveće, onda je stupanj uništenja 4*



ili 3, pa opet 4, dok je tu kod bjelogorične bilo 1, pa 3 (op.a. što bi zapravo sugeriralo da je crnogorična šuma uništenija).....*Recimo i kukci idu više na bjelogorično drveće, zato što nema toliko one smole unutra...To smo učili iz biologije, zapravo iz prirode i društva. Tako da kad kukci napadnu bjelogorično drveće, to je onda opasno.....*». Ovaj citat ukazuje na poteškoće koje Lena ima u koordiniranju podataka prikupljenih eksperimentima i vlastitih teorija o učinku ovog čimbenika, a ujedno i prikazuje njezinu izrazitu potrebu osmišljavanja nalaza eksperimenata pomoću različitih objašnjenja koja može dozvati iz pamćenja, a koja joj djeluju uvjerljivo. Vidljivo je, također, da kod Lene dolazi do miješanja podataka iz eksperimenata s vlastitim teorijama u jedinstvenu reprezentaciju toga «kako stvari djeluju». Iako početak izjave govori da je Lena svjesna da je porijeklo njezinog zaključka u «znanjima» koja od prije posjeduje, iz nastavka tvrdnje je očito da na određeni način uzima u obzir i prikupljene podatke, iako tako da ih iskrivljuje i koristi kao ilustraciju i potvrdu ispravnosti svojih teorija. Naime, kao dokaz svoje teorije o većoj uništenosti bjelogoričnih šuma Lena navodi rezultate koji se postižu uz pojedinu vrstu šume, pri čemu ne osvještava da je niže rezultate eksperimenata zapravo proizvela uz bjelogoričnu, a ne uz crnogoričnu šumu. Iako je njezin novi zaključak točan, ona ne uviđa nemogućnost donošenja valjanih zaključaka na temelju nalaza koje je proizvela, već i dalje, u sljedećim pokusima nastavlja raditi pokuse u kojima čimbenike bira na nekontroliran način.

Važno je, međutim, napomenuti da postojanje složenih teorija o učinku vrste šuma na njihovo uništenje, kao i osmišljavanje potencijalnih kauzalnih mehanizama u osnovi tih teorija kod Lene otvara put razmatranju interakcijskih učinaka, pa ona već u osmom pokusu donosi jedan takav zaključak i kaže «*Kukci nemaju previše učinka na crnogorično drveće. Ni učinak kiselih kiša na njih nije jak, tako da je drveće još snažno....I brdoviti teren je pogodan za crnogorično drveće*». Iako je taj zaključak nevaljan i zapravo teorijski utemeljen, on označava začetak razmišljanja o složenijim odnosima varijabli unutar multivarijatnog sustava. Međutim, u kasnijim fazama rada na zadatku (tijekom drugog do četvrtog mjerenja), Lena potpuno zanemaruje mogućnost interakcijskih odnosa među varijablama, i nastavlja uglavnom s nevaljanim zaključivanjem o jednostavnim odnosima, kao i u prvom mjerenju.

Od prvog do četvrtog mjerenja Lena ne pokazuje značajan napredak prema valjanijem zaključivanju. U kasnijim je mjerenjima, doduše, uočeno da se češće nego u prvoj situaciji rada na zadatku susteže od donošenja zaključaka, što može sugerirati da počinje zapažati

da je u slučaju nekontroliranih pokusa nemoguće nešto pouzdano zaključiti o učinku ispitivanih čimbenika na uništenje šuma, ali se može tumačiti i kao posljedica njezine negativne motivacije za rad na zadatku i stava *«Ne mogu ništa zaključiti – ne radi mi mozak i ne da mi se više»* (o čemu će biti riječ malo kasnije).

Od prvog do četvrtog mjerenja također se zapažaju svojevrsne promjene u vrsti nevaljanih zaključaka koje Lena donosi – iako su i dalje prisutni generalizirani zaključci, nestaju potpuno teorijski utemeljeni zaključci i zaključci temeljeni samo na jednom eksperimentu, a češće se pojavljuju zaključci utemeljeni na nekontroliranoj usporedbi dva eksperimenata. Takav jedan zaključak Lena donosi već na početku drugog mjerenja. Izvela je prvi pokus tako da dobije minimalan stupanj uništenja šume kombiniranjem bjelogorične šume, brežuljkastog pojasa, udaljenosti od naselja, rijetkog padanja kiselih kiša i nepostojanja nametnika. U trećem pokusu je željela pokazati drugi stupanj uništenja šume pa je izabrala bjelogoričnu šumu, nizinski pojas, udaljenost od naselja, vrlo često padanje kiselih kiša i nepostojanje nametnika. Kad se pokazalo da je ishod trećeg eksperimenata bio trojka, Lena je izjavila: *«Trojka?!?!? To me jako čudi, jer je dva stupnja razlike između brdovitog i ravnog terena u prvom i trećem redu.....Dobro... valjda je u terenu razlika! Zaključujem da je u terenu razlika!»*. Lena ovime pokazuje jasnu orijentiranost na usporedbu dva pokusa, ali zanemaruje da je između ta dva eksperimenta, osim konfiguracije tla, promijenjen i čimbenik kiselih kiša, pa donosi netočan i nevaljan zaključak o učinku konfiguracije tla. Valjan ekskluzivan zaključak o ovome čimbeniku Lena donosi tek u zadnjem mjerenju, kad taj zaključak predstavlja ujedno i prvi valjan ekskluzivan zaključak koji ona donosi.

Pomak od teorijski utemeljenih zaključaka prema zaključcima utemeljenima na nalazima koji se zapaža kod Lene tijekom rada na zadatku istraživačkog učenja može se tumačiti kao određeni napredak u njezinom strateškom djelovanju, iako ona nikad ne doseže razinu koju označava jasni prijelaz na valjano zaključivanje. Tek u trećem i četvrtom mjerenju pojavljuju se među nevaljanim zaključcima i poneki valjani zaključci koji se temelje na korištenju strategije kontrole varijabli i na nedvojbenoj usporedbi provedenih eksperimenata. Osim toga, vrijedi spomenuti da je znanje o kauzalnoj strukturi modela zadatka koje je Lena stekla kroz rad na zadatku vrlo skromno – Lena završava istraživanje s neotkrivenim interakcijskim i nelinearnim učincima, te s netočnim teorijama o učincima konfiguracije tla i udaljenosti šuma od naselja.

Iako se može tvrditi da se razlozi Leninog slabog napredovanja u strateškoj izvedbi na zadatku istraživačkog učenja mogu pronaći u relativno kratkoj mogućnosti uvježbavanja

ispitivanih vještina za vrijeme provedbe istraživanja, čini se da se glavni izvori Leninog niskog učinka na zadatku istraživačkog učenja mogu pronaći u metakognitivnim, ali i motivacijskim elementima. Tijekom cjelokupnog rada na zadatku Lena nije razvila zadovoljavajuću razinu metakognitivnog razumijevanja cilja zadatka, budući da sve do kraja ispitivanja nije odustala od provođenja eksperimenata s ciljem generiranja specifičnih ishoda eksperimenata. To potvrđuje i njezina izjava prikupljena u završnom metakognitivnom upitniku uz pitanje o cilju zadatka: *«Cilj mi je bio biti uspješna na zadatku, što znači pogoditi sve stupnjeve uništenosti pomoću sličica»*, koja sugerira da je Lena, u najboljem slučaju, zastala na razumijevanju zadatka kao onog u kojem treba ispitati koliko će šuma biti uništena u različitim kombinacijama čimbenika. Uz nepostojanje metakognitivnog razumijevanja cilja zadatka kao onog u kojem se ispituje učinak pojedinih čimbenika na uništenje šuma, jednako problematično je i Lenino metastrateško znanje. Upitana o tome kako odrediti koje sličice treba birati za pojedini eksperiment, Lena daje nespecifičan odgovor: *«Moraš imati neku svoju taktiku i ići po nekom redoslijedu»*. Iako Lena ovdje ne eksplicira o kakvoj se taktici radi i po kakvom redoslijedu treba ići (zbog čega je odgovor označen kao razina «0»), iz njezinog pristupa radu na zadatku jasno je da je to pristup generiranja svih pet mogućih stupnjeva uništenja šuma.

Razumijevanje zadatka istraživačkog učenja na ovaj način zasigurno je priječilo Lenu u zauzimanju pristupa koji omogućuje utvrđivanje učinka pojedinih čimbenika na uništenje šuma (na valjan način).

Međutim, čini se izvjesnim da je nisku razinu postignuća koju je Lena iskazala na zadatku značajnim dijelom uvjetovao i negativan stav koji je imala prema radu na zadatku i pristup koji je iz toga proizašao. Lena je jedna od rijetkih ispitanica kojoj je od prvog do četvrtog mjerenja izrazito pao (do najnegativnijeg stupnja) interes za zadatak, sviđanje zadatka te raspoloženje za rad na njemu. O padu motivacije govori i Lenino viđenje trenutka završavanja rada u pojedinom mjerenju. Dok je, po njezinoj procjeni, prvo mjerenje završila kad je bila izrazito zadovoljna postignutim rješenjem, treće je mjerenje završila kad joj je postalo dosadno i nije joj se više dalo raditi, a četvrto kad joj je bilo svega dosta i nije više mogla izdržati.

Lena nije pokušavala sakriti svoju negativnu motivaciju od istraživačice, pa je često verbalno i neverbalno izražavala osjećaje dosade, nezainteresiranosti, umora, nemotiviranosti za nastavak rada i nespremnost za ulaganje truda. Kad joj je u kasnijim

situacijama učenja najavljeno da će ponovno raditi na istom zadatku, rekla je «*Oh, ne! Opet ono!*» ili «*Joj! Već četvrti put se ponavljam! Baš se veselim ; (»*).

O Leninoj motivaciji za rad na zadatku mnogo govori i opažanje da je gotovo kod svakog sljedećeg eksperimenta koji je trebala napraviti uzdisala i puhala, te je često izricala nešto kao «*Uhhh! Puhhhh!....Još ima?! A joj!*», «*O moj Bože! Nadam se da ću moći još dva napraviti!*» ili «*Jel' moram još? Stvarno sam se umorila!*». Zanimljivo je, međutim, da je Lena sve svoje eksperimente provela spontano, bez poticanja od strane istraživačice. To je, s jedne strane, bilo posljedica činjenice da u manje od 10 eksperimenata nije uspijevala pokazati svih pet mogućih ishoda eksperimenata, pa je s radom nastavljala sve dok nije ostvarila taj cilj, dok je, s druge strane, bilo uvjetovano njezinom željom da što duže izbiva s nastave. Tijekom trećeg mjerenja je tako rekla: «*Joj, malo sam to sve prebrzo radila....Koliko ću redova još napraviti ovisi o tome koliko je sati....hoću li stići na kemiju?*». Stoga i ne čudi što je Lena provodila dio eksperimenata, posebice onih kasnijih tijekom pojedinih mjerenja bez ikakvog cilja i namjere. U tim je slučajevima izjavljivala: «*Sad ću bubnut nešto, pa kaj ispadne....*».

Opazanje i analiza Leninog ponašanja tijekom rada na zadatku sugerira da se njezina negativna motivacija, udružena s visokom (i stabilnom) percepcijom vlastite samoeфикаsnosti, te procjenom zadatka kao laganog i onog u koji treba ulagati tek osrednji trud, očitovala u pristupu radu koji je Lena zauzela tijekom istraživanja. Opći je dojam istraživačice da je Lena provodila eksperimente nekoncentrirano, nemarno, bez previše razmišljanja i ulaganja truda. Relativno brzo i bez napora je odabirala kombinacije čimbenika, a jednako tako je donosila zaključke, a poslije poneke i mijenjala, bez jasne svijesti o postojanju te promjene. Kad su rezultati eksperimenata bili različiti od njezinog predviđanja, obično se pomalo začudila, te uz osmijeh komentirala npr. «*Ups, 3! Opet sam fulala! Ali nema veze!*», nakon čega bi, obično na poticaj istraživačice o mogućem zaključku, krenula objašnjavati razloge dobivenih rezultata. Kad su se predviđeni i stvarni rezultati eksperimenata podudarali, ponekad bi zadovoljno uzviknula: «*Ajde hvala ti Bože da sam nešto pogodila!*», a ponekad bi se samo osmjehnula i rekla «*Eto!*».

Iz Leninih iskaza tijekom rada na zadatku bilo je jasno da unaprijed nije planirala kako provesti zadatak, već da je o provedbi eksperimenata odlučivala neposredno nakon što bi pojedini pokus već provela. Često je nakon provedbe pojedinog pokusa govorila: «*Majko Božja, što bih sad mogla?*» ili «*Uhhh, nemam više ideja!*», te je sljedeći pokus na neki način nastavljala na prethodni, iako ih nije nužno i uspoređivala. Stoga je Lenin rad na

zadatku okarakteriziran kao lokalno ulančavanje u svim mjerenjima, osim u prvom, kad nije bilo vidljivo postojanje ikakvog plana ili organizacije rada na zadatku, niti je uočen neki logičan redoslijed provedbe pojedinih eksperimenata.

Osim nedostatnog planiranja rada na zadatku i nesustavnog pristupa biranju kombinacija čimbenika, analiza Leninog ponašanja tijekom istraživanja ukazuje i na manjak metakognitivnih aktivnosti praćenja i regulacije rada na zadatku. Od ponuđenih funkcija programa FILE, Lena je u nekoliko slučajeva iskoristila tek funkciju vraćanja na prethodne rezultate eksperimenata (uz komentar tipa «*Samo malo da ja tu nešto vidim....*»), dok ostale mogućnosti programa nije upotrijebila. Opažanje korištenja metakognitivnih vještina također govori o tome da je u Leninom verbalnom protokolu vrlo malo izjava koje sugeriraju nekakvu metakognitivnu aktivnost. Naime, Lena nije pokazala posebnu analitičnost ili refleksivnost u radu na zadatku, pa se glavnina njezinih izjava odnosi tek na navođenje sličica koje upravo bira i objašnjenje postignutog ishoda eksperimenta, dok izostaju izjave koje bi sugerirale da Lena prati provedbu eksperimenata, uočava eventualan loš izbor eksperimenata ili nelogične nalaze, provjerava ispravnost svojih zaključaka, razmišlja o tome što još treba učiniti i slično. Tek povremeno zabilježene se izjave koje potvrđuju da Lena ima neku refleksiju na proces rada, na primjer, kad uočava da je proizvela ishod 1, pa 2 pa 3, pa joj još nedostaje ishod 4, kad navodi da će slijedeći pokus provesti kao suprotnost prethodnog, ili kad povezuje svoja očekivanja s rezultatima prethodnih pokusa («*To će biti 5. Toga se već dobro sjećam*»). O nedostatnom praćenju tijeka učenja govori i činjenica da Lena nije primijetila da je neke eksperimente ponovila (u trećem mjerenju čak tri eksperimenta je dvaput izvedeno), već ih je tretirala kao posve nove eksperimente.

### *Oliver*

Za razliku od Lene, Oliver je u istraživanje istraživačkog učenja ušao kao predstavnik učenika ispodprosječnih induktivnih sposobnosti prema rezultatu na Testu nizova, dok je u studiju slučajeva uključen kao učenik kojeg karakterizira pozitivna motivacijska orijentacija. Kao i Lena, Oliver ostvaruje nisku razinu strateške izvedbe na zadatku istraživačkog učenja. Osim što ne uspijeva postići značajniji napredak u valjanosti zaključaka od prvog do četvrtog mjerenja, istraživanje završava (kao i Lena) s prilično skromnim znanjem o odnosima između varijabli u zadatku o uništenju šuma. Zadnji razgovor o teorijama koje ima o učincima pojedinih čimbenika na uništenje šuma upućuje

na netočne (inkluzivne) teorije o utjecaju konfiguracije tla i udaljenosti šuma od naselja, te na neotkrivanje nelinearnog učinka kiselih kiša.

Zbog razlika u motivacijskoj orijentaciji, a sličnosti u učinku na zadatku, Oliver i Lena predstavljaju zanimljive slučajeve za razmatranje međuodnosa motivacije i procesa istraživačkog učenja, budući da upućuju na ponešto različite mehanizme koji mogu biti u osnovi nezadovoljavajućeg uspjeha u istraživačkom učenju.

Na početku, važno je reći da su Oliverove motivacijske procjene značajno pozitivnije od Leninih u svim mjerenjima, a ukazuju i na potpuno drugačiji smjer promjena kroz četiri mjerenja. Dok je kod Lene bilo prisutno smanjivanje interesa za zadatak i raspoloženja za rad od prvog do četvrtog mjerenja, kod Olivera procjena početnog interesa za zadatak raste s 4 (u prvom i drugom mjerenju) na 5 (u trećem i četvrtom mjerenju), a procjena emocionalnog stanja i raspoloženja za rad održava se na istoj, izrazito pozitivnoj, razini tijekom svih mjerenja. Oliverova procjena samoeфикаsnosti također raste nakon prvog mjerenja (s tri na pet) i zadržava se na maksimalnoj razini sve do kraja istraživanja. Zapravo, već nakon provedenih prvih četiri eksperimenata, Oliver konstantno (sve do kraja istraživanja) procjenjuje vlastitu sposobnost za rješavanje zadatka izrazito visokom, uloženi trud maksimalnim, a zadatak izrazito laganim.

U odnosu na Lenu, uz navedene razlike u procjenama interesa i raspoloženja za rad, Oliver tijekom svih mjerenja iskazuje veću spremnost za nastavljanje rada, daje veću važnost postizanju uspjeha na zadatku, kao i više procjene potrebe i namjere ulaganja truda, te procjene uloženog truda.

Opažanje Oliverovog motivacijskog ponašanja tijekom rada na zadatku ostavlja ponešto drugačiji dojam od ovog temeljenog na samoiskazanim učenikovim procjenama. Analiza verbalnih protokola pokazuje da Oliver daje vrlo malo spontanijh izjava koje bi označavale, primjerice, doživljaj (ne)uspjeha, interes za zadatak, (ne)spremnost za ulaganje truda, emocionalne reakcije na zadatak i slično. Tek povremeno Oliver izriče neke rečenice koje sugeriraju zainteresiranost za aktivnost ili zadovoljstvo obavljenim: *«Baš me zanima što će sad ispasti»* ili *«Super! Kad bismo ovako radili, onda bismo mogli pomoći tim znanstvenicima!»*. Dakako, mali broj ovakvih izjava ne dovodi, sam po sebi, u pitanje postojanje Oliverove visoke motiviranosti za rad na zadatku. Neverbalni znakovi, pak, upućuju na postojanje određene napetosti i nesigurnosti kod Olivera, posebice u ranijim fazama rada na zadatku, dok pozitivna neverbalna ekspresija uglavnom izostaje. Tijekom

rada na zadatku Oliver pokazuje značajan motorički nemir – konstantno se ljulja i miče, maše rukama, trlja oči, šara po papiru koji je predviđen za vođenje bilježaka itd. To ponašanje se očituje i u stilu govora koji prati provedbu eksperimenata – uglavnom govori brzo, pomalo zamuckuje, prekida jednu rečenicu i započinje drugu bez završavanje prve i slično. Djeluje brzopletost ne samo u govoru, nego i u načinu na koji pristupa zadatku. Oliver, međutim, pokušava kontrolirati takva ponašanja, pa su unutar pojedinih mjerenja vidljivi i trenutki kad djeluje mirnije, usporenije, koncentriranije i usredotočeno na zadatak. U tim trenucima Oliverove izjave uobičajeno ukazuju na postojanje različitih metakognitivnih aktivnosti, odnosno upućuju na pokušaje praćenja rada na zadatku, kao i na pokušaje povezivanja i sumiranja rezultata različitih eksperimenata. Primjerice, nakon nekog provedenog pokusa, Oliver donosi zaključak o jednom čimbeniku, ali usput ponavlja sve ostale zaključke koje je donio do tog eksperimenta, kako bi ih utvrdio u pamćenju i povezo s novim nalazima. Nadalje, on ponekad sam sebe upućuje na usporavanje i zaustavljanje, kako bi se mogao osvrnuti na nalaze već provedenih eksperimenata, orijentirati u zadatku i osmisliti sljedeći eksperiment, pomoću riječi «*Samo malo!*» ili «*Hm, ne znam što bih....da razmislim.....*». U nekoliko navrata Oliver koristi i funkcije programa koje omogućuje vraćanje na prethodne eksperimente i organizaciju podataka, uz komentare tipa «*Da vidim samo nešto.....Stavio sam ovo i ovo i ovo. Aha - kužim!*». Iako je ovakvih primjera korištenja metakognitivnih vještina kod Olivera više nego kod Lene, vjerojatno zbog njegove veće spremnosti ulaganja truda i napora u procesiranje zadatka, te aktivnosti niti kod Olivera nisu prisutne konstantno tijekom rada unutar pojedinih mjerenja, već se trenutki promišljenog i refleksivnog eksperimentiranja izmjenjuju s površnim, nepromišljenim i brzopletim pristupom. O tome zasigurno govori i opažanje da Oliver, češće nego drugi ispitanici, pri odabiru čimbenika za pojedini eksperiment nenamjerno preskače pojedini čimbenik pa ga naknadno uvrštava, ili mijenja odluku o tome koju sličicu izabрати pa koristi tipku 'vрати natrag'. Osim toga, kod Olivera je zabilježeno i nenamjerno korištenje funkcije selekcije eksperimenata, o čemu svjedoči njegov komentar: «*Što je sad? Jesam nešto pokvario?*».

Opći dojam brzopletosti koji Oliver ostavlja na istraživačicu očituje se i u činjenici da tijekom svih četiri mjerenja zauzima prilično nesustavan pristup u izboru eksperimenata te provodi eksperimente bez jasnog, unaprijed definiranog plana (u čemu se ne razlikuje od Lene). Niti u jednom mjerenju Oliver ne došije razinu planiranja rada na zadatku višu od lokalnog ulančavanja eksperimenata. To znači da eksperimente ne provodi po nekom

(logičnom) redu, već o njihovom slijedu odlučuje ad hoc, kad ga «zavedu» nalazi prethodnih eksperimenata.

Neplanski i nesustavan pristup kojim Oliver rješava zadatak, a koji predstavlja značajan metakognitivni deficit za uspješan rad na zadatku istraživačkog učenja, zasigurno je povezan s nalazom o nedostatnom metakognitivnim znanju s kojim on započinje, ali i završava rad na zadatku istraživačkog učenja. Naime, analiza početnog metakognitivnog znanja pokazuje da Oliver nema nikakav uvid o potrebi korištenja neke strategije kako bi zadatak uspješno riješio, budući da na pitanje o tome kako birati sličice u pojedinim eksperimentima odgovara: «*Po nekom slučaju*». Početno razumijevanje cilja zadatka na ponešto je višoj razini, s obzirom da ciljem zadatka vidi «*razotkrivanje razloga kašnjenja Petra*», što upućuje na razumijevanje zadatka kao onog kojim se želi utvrditi što utječe na postizanje određenih ishoda eksperimenata.

Nakon četiri situacije rada na zadatku istraživačkog učenja, kod Olivera dolazi do određenih promjena u iskazanom metakognitivnom razumijevanju cilja zadatka i strategija rada na njemu, iako se ne približava razini koja jamči analitičku usmjerenost na utvrđivanje učinaka pojedinih čimbenika putem usporedbe kontroliranih eksperimenata. Upitan o cilju zadatka nakon rada na zadatku o uništenju šuma, Oliver odgovara odgovorom koji upućuje na shvaćanje zadatka kao onog u kome treba ostvariti pozitivan rezultat (smanjenje uništenja šuma): «*Učenik treba sav svoj trud posvetiti ovom zadatku, jer se ovaj zadatak tiče i samog učenika. Cilj učenika je riješiti problem zagađenosti šuma. Treba postići rješenje o tome kako spriječiti zagađenje*». S ovakvim razumijevanjem cilja zadatka usklađen je i odgovor o potrebnoj strategiji rješavanja zadatka koji kaže da «*Treba prvo tražiti najgoru kombinaciju, a onda ići prema sve boljim kombinacijama*», iako se on zapravo može tumačiti i kao primjer više razine metastrateškog znanja koju označava pristup po kojemu učenik odabire različite kombinacije čimbenika, s ciljem opažanja rezultata do kojih te kombinacije dovode.

Dosad izneseni nalazi o Oliverovom pristupu rada na zadatku istraživačkog učenja već ukazuju na mogućnost da nezadovoljavajuća razina strateške izvedbe na zadatku proizlazi iz Oliverovih metakognitivnih manjkavosti, prije svega, iz nesposobnost planiranja i iz korištenja nesustavnog pristupa u radu, što se može povezati i s nedostatnim razumijevanjem zahtjeva zadatka i podejnjivanjem zadatka kao laganog. Potrebno je, međutim, ukazati i na neke teškoće na koje Oliver nailazi tijekom eksperimentiranja i zaključivanja, a koje se prvenstveno odnose na probleme koordinacije teorija koje Oliver



ima o učinku čimbenika na uništenje šuma i nalaza koje prikuplja kroz eksperimentiranje. Kao ilustracija tipičnih problema s kojima se Oliver susreće poslužit će eksperimenti iz prvog mjerenja (prikazani u okviru 2), u kojima Oliver donosi zaključke o utjecaju konfiguracije tla. Podsjetimo da je to čimbenik o kojem Oliver do kraja istraživanja nije izveo točnu teoriju.

### Okvir 2

Nalazi koje je Oliver stvorio tijekom prvog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
1	1	crnogorica	nizina	blizu	vrlo	ima	4	4
1	2	bjelogorica	brijeg	blizu	vrlo	nema	4	3
1	3	crnogorica	nizina	blizu	vrlo	nema	4	3
1	4	crnogorica	brijeg	blizu	cesto	ima	4	4
1	5	bjelogorica	brijeg	daleko	vrlo	ima	4	5
1	6	bjelogorica	nizina	blizu	rijetko	nema	1	1
1	7	crnogorica	brijeg	blizu	vrlo	ima	4	4
1	8	bjelogorica	nizina	daleko	rijetko	nema	1	1
1	9	crnogorica	nizina	blizu	cesto	nema	3	3
1	10	crnogorica	brijeg	blizu	vrlo	ima	5	4
1	11	crnogorica	nizina	blizu	vrlo	ima	5	4
1	12	bjelogorica	nizina	blizu	vrlo	ima	5	5

Oliver započinje rad na zadatku o uništenju šuma s kauzalnim teorijama o nametnicima, kiselim kišama i udaljenosti šuma od naselja, te s nekauzalnom teorijom o konfiguraciji tla. O vrsti drveća u šumi nema čvrstu teoriju, iako odmah iznosi mišljenje da je moguće da nametnici više napadaju određenu vrstu šuma (bjelogoričnu), kao i da šumama određene vrste odgovara smještaj u određenom pojasu (bjelogoričnim u nizinskom, a crnogoričnim šumama u brežuljkastom pojasu).

Tijekom prvog mjerenja Oliverovi eksperimenti su uglavnom izvedeni s nejasnom namjerom, budući da on nije težio ispitivanju učinka pojedinih čimbenika, već se usmjeravao na postavljanje cjelokupnih kombinacija čimbenika i opažanje rezultata do kojih te kombinacije dovode. Bez postojanja namjere ispitivanja pojedinih čimbenika, logično je što Oliver prije izvođenja pojedinih eksperimenata uglavnom nije elaborirao vlastita očekivanja, odnosno nije iskazivao hipoteze o učinku čimbenika na uništenje šuma.

Kao i Lenino, Oliverovo eksperimentiranje i zaključivanje o utjecaju čimbenika na uništenje šuma pod velikim je utjecajem njegovih prethodnih očekivanja i teorija. Iako je gotovo od početka u svoja razmišljanja i zaključke na određeni način uključivao nalaze

koje je proizveo, to nije bilo objektivno i nepristrano. Velik dio zaključaka koje je Oliver donio mogu se smatrati na teoriji utemeljenim zaključcima (koji su kao takvi nužno nevaljani), jer se pri njihovom donošenju Oliver nije jasno referirao na nalaze provedenih eksperimenata. Tek je manji dio zaključaka nedvojbeno temeljen na prikupljenim nalazima, ali je uglavnom izveden putem usporedbe dvaju ili više pokusa provedenih na nekontroliran ili nekontrastan način.

U prvom eksperimentu koji je izveo, Oliver je odabrao kategorije čimbenika (blizinu naselju, nametnike i vrlo česte kisele kiše), koje po njegovim teorijama imaju kauzalni učinak na povećavanje stupnja uništenja šuma. Pritom nije izrazio namjeru istraživanja *«najgore kombinacije»*, već samo to da *«želi vidjeti koliko će biti uništenje»*. Nakon što je uočio da njegovo predviđanje odgovara stvarnom stupnju uništenja šuma (4), bio je zadovoljan postignutim, te je odmah počeo konstruirati drugi eksperiment. U tom je eksperimentu namjerno promijenio vrstu šume i konfiguraciju tla te oduzeo nametnike, kako bi vidio *hoće li se što promijeniti s bjelogoricom, na brežuljku i bez nametnika*. Iako promjenom svih tih čimbenika, dakako, nije bilo moguće donijeti valjani zaključak niti o jednom od navedenih čimbenika, Oliver se nije sustezao na temelju nekontrolirane usporedbe prvog i drugog eksperimenta zaključiti sljedeće: *«Dobio sam srednju vrijednost, što znači da uništenje jest i nije moguće.....(Možeš li nešto zaključiti o učinku čimbenika na uništenje šuma?) Mogu zaključiti da tlo nema veze i da ako nema nametnika manja je šteta.....Nisam siguran ima li vrsta šume učinka, ali čini mi se da ove crnogorične šume bolje podnose nametnike»*. Ovaj citat ukazuje da u interpretiranju rezultata eksperimenata Oliver zapravo ponavlja vlastite teorije o pojedinim čimbenicima, koristeći kovarijaciju prisutnih čimbenika za potvrdu teorija koje već ima o tim čimbenicima. Pritom, za objašnjenje je uzeo u obzir samo čimbenike koje je varirao, dok ostale nije smatrao odgovornima za ostvareni rezultat (iako su nalazi isti). Manji stupanj uništenja šuma koji postoji uz drugu kombinaciju čimbenika pripisao je utjecaju nametnika, i nepostojanju utjecaja konfiguracije tla. Uz to, iznio je i nesigurnu tvrdnju o međuodnosu vrste šume i nametnika, koja, iako točna (!), uopće nije utemeljena u podacima, budući da oni nisu bili generirani.

U slijedećem (trećem) eksperimentu Oliver se vraća na ispitivanje crnogorične šume u nizinskom pojasu kao u prvom eksperimentu, te izjavljuje da želi ispitati kakvo će biti uništenje ukoliko nema nametnika. Iako koristi valjani test za ispitivanje učinka nametnika (budući da između prvog i trećeg pokusa formira razliku samo u kategoriji čimbenika

'pojava nametnika'), Oliver ne uspijeva ispravno uočiti nalaze o nižem stupnju uništenja šuma u situaciji bez nametnika (u odnosu na situaciju s nametnicima), te ih interpretirati upravo pomoću učinka tog čimbenika. Vjerojatno uslijed smetenosti i užurbanosti s kojom Oliver izvodi ovaj eksperiment, ali i zbog toga što mu vlastite teorije nameću razmišljanje o kauzalnosti različitih čimbenika, te o njihovim međusobnim interakcijskim odnosima, fokus s valjanog testa o učinku 'pojave nametnika' prebacuje se na nevaljanu usporedbu sva tri do tada napravljena eksperimenta. Iako je u prvi mah Oliverov zaključak bio nejasan i neorganiziran («*Opet trojka! Mislim da je to vezano s vrstom šuma... (prekid)... ako ima nametnika...(prekid)... mislim da i tlo ima veze!...(prekid)*»), na poticaj istraživačice (Govori li ti nešto u podacima o utjecaju ovih čimbenika?) Oliver daje objašnjenje koje u prvi plan stavlja učinak čimbenika 'konfiguracija tla': «*Vidio sam u prvom retku kada sam stavio da je ravno tlo, crnogorica, velika količina kiša, blizina naselja i nametnici da je ispalo 4, a kada sam stavio brežuljkasto tlo i da nema nametnika ispala je trojka....Zato mislim da i tlo ima nekakve veze s ovime....Ako je šuma na uzvišenju možda ima neke pogodnosti, jer naselja se ne rade na nekom uzvišenju, nego na nizini*». Ovaj citat govori o tome da se Oliver u interpretaciji trećeg eksperimenta zapravo vraća na nalaze prijašnjih eksperimenata i usporedbu prvog i drugog pokusa. Pritom, kao moguće objašnjenje opažene razlike u rezultatima ističe konfiguraciju tla, dok komentar o učinku nametnika sasvim izostaje (iako opaža da je u situaciji bez nametnika, uništenje šuma manje). Podsjetimo da je Oliver u treći eksperiment upravo ušao s namjerom ispitivanja nametnika, te da ova opažena nekoordiniranost između namjere i donesenog zaključka sugerira određene Oliverove istraživačke slabosti i manjak praćenja procesa rada na zadatku. O istome govori i nalaz o tome da Oliver, objašnjavajući u trećem eksperimentu učinak konfiguracije tla na temelju usporedbe provedenih pokusa, sasvim zapostavlja činjenicu da je u drugom eksperimentu (u odnosu na prvi eksperiment), osim konfiguracije tla i nametnika, bila varirana i vrsta šume koja je mogla biti odgovorna za promjene u rezultatu. Uz to, Oliver ne razumije da mu za valjanu usporedbu crnogorične šume u nizinskom pojasu nedostaju podaci o uništenju crnogorične šume na brežuljkastom terenu, koji još nisu niti izvedeni. Kao posljedica provedene nevaljane usporedbe eksperimenata, Oliver mijenja vlastitu teoriju o konfiguraciji tla i tom čimbeniku počinje pridavati kauzalni (zapravo netočan) status.

U sljedeća dva eksperimenta (četvrtom i petom) Oliver nesustavnim variranjem čimbenika i korištenjem kategorije 'brijeg' nastavlja «potvrđivati» svoju novu teoriju o kauzalnosti

konfiguracije tla. Ti su eksperimenti, u kojima je crnogorična šuma na brežuljkastom pojasu dala uništenje četvrtog stupnja, a bjelogorica šuma na brežuljkastom pojasu bila povezana s najvišim stupnjem uništenja, pružili Oliveru priliku (nevaljane) potvrde njegove početne teze o međusobnoj zavisnosti učinaka konfiguracije tla i vrste šume. Komentirajući rezultat petog eksperimenta, Oliver daje objašnjenje koje se jasno temeljilo upravo na tim teorijskim razmatranjima: *«Petica! Znači sad je velika opasnost!.....Mislim da tlo ima veze. Mislim da nije dobro da ova šuma bude na visokom tlu, kad ta šuma nije baš predviđena da tu bude, nego na ravni....Mislim da imaju veze i šume i tlo.....Znam da ima neki pojas gdje šume mogu rasti, a ako ih stavimo drugdje, bit će velika opasnost za te šume i veliko uništenje»*. Ideju o povezanosti vrste šuma i konfiguracije tla Oliver nastavlja i u kasnijim eksperimentima (šestom do osmom), kad pri izboru čimbenika u kombinacije uparuje bjelogoricu i nizinu, te crnogoricu i brijeg kao *«šume koje su predviđene za to tlo»*. Uparivanjem ovih kategorija čimbenika i njihovim nevariranjem u ovim eksperimentima, Oliver zapravo osigurava nepodvrgavanje svoje teorije o učinku konfiguraciji tla ozbiljnijoj empirijskoj provjeri. Do toga ipak ubrzo dolazi, već nakon 10. eksperimenta u istom mjerenju, kad dolazi do jednog zanimljivog razvoja situacije. Naime, deseti eksperiment Oliver postavlja kombiniranjem crnogorice na brežuljkastom pojasu i drugih čimbenika koji po njegovim teorijama donose maksimalno uništenje. Taj pokus zapravo predstavlja ponavljanje sedmog pokusa, ali Oliver to ne uviđa. Kad se umjesto očekivanog stupnja 5, otkrilo da je stupanj uništenja za provedenu kombinaciju čimbenika 4, Oliver se iznenadio (a isti rezultat ga dva eksperimenta ranije nije čudio!). To ga je nagnalo da duže promotri nalaze koje je stvorio, te da razmisli o razlozima dobivenog rezultata. Iako je rekao: *«Pa pojma nemam zašto sam dobio četvorku»*, to ga je potaknulo da u 11. pokusu svjesno valjano varira samo konfiguraciju tla. Prije dovršavanja tog eksperimenta objasnio je svoj izbor: *«Da vidim samo kad bih ovako stavio....Stavit ću da je šuma na ovome tlu i samo ću promijeniti tlo, a sve ostalo ću ostaviti isto»*. Sad je uz ovu kombinaciju čimbenika očekivao najviši stupanj uništenja šuma, pa je nakon završetka eksperimenta opet bio «prisiljen» razmišljati o tome zašto je ponovno dobio četvorku. Po dugoj stanci i usredotočenosti na ekran bilo je očito da se kod Olivera ponovno počela pojavljivati ideja o tome da konfiguracija tla nema veze s uništenjem šuma, ali je on pokušao još jednom zaštititi svoju do tada kauzalnu teoriju skretanjem na druge čimbenike koji mogu objasniti ostvareni ishod. Tako Oliver prvo izjavljuje: *«Sve zavisi kakva je šuma....neke šume ne reagiraju baš na nametnike...U ova dva pokusa što sam napravio, mislim da ima veze vrsta šume (op.a. vrstu šume nije ni varirao!)»*, ali na kraju ipak izjavljuje i *«Mislim da nema*

*veze konfiguracija tla*». U sljedećem, posljednjem eksperimentu prvog mjerenja Oliver želi provjeriti svoj zaključak iz prošlog eksperimenta o utjecaju vrste šuma, pa ga opet strukturira kao valjan test promjenom kategorije u čimbeniku 'vrsta šume'. Rezultat potvrđuje njegovo očekivanje o većem stupnju uništenja u ovoj kombinaciji koja sadrži bjelogoričnu šumu, ali umjesto da se ograniči na donošenje valjanog zaključka o glavnom učinku vrste šuma, Oliver zaključuje: «*Mislim da bjelogorične šume.....da im više štete nametnici, kisele kiše i blizina naselja nego što štete crnogorici*».

Iz provedbe ovih zadnjih eksperimenata unutar prvog mjerenja moguće je uočiti nekoliko važnih elemenata koji upućuju na moguća objašnjenja Oliverove niske razine strateške izvedbe na zadatku istraživačkog učenja. Podaci pokazuju da Oliver relativno rano u radu na zadatku počinje postavljati eksperimente i odabirati kombinacije čimbenika na način koji omogućuje donošenje valjanih zaključaka o učinku pojedinih čimbenika (podsjetimo da se kod Lene to dešavalo tek u drugom dijelu istraživanja!). Iako Oliver u tim trenucima namjerno mijenja samo jedan čimbenik, kod njega izostaje metakognitivna svjesnost o važnosti korištenja strategije kontrole varijable, kao i o prednostima koje proizlaze iz kontrolirane usporedbe eksperimenata za valjano zaključivanje o učinku pojedinih čimbenika, pa u fazi donošenja zaključka ne uspijeva sasvim kapitalizirati to valjano izvedeno variranje čimbenika između pojedinih eksperimenata. Tako se, primjerice, pri donošenju (valjanog) zaključka o učinku konfiguracije tla u 11. eksperimentu prvog mjerenja on ne osvrće direktno na usporedbu tih kontroliranih eksperimenata, iako je očito da zaključak i ponovna promjena teorije o čimbeniku proizlazi upravo iz tih prikupljenih nalaza.

Podaci, također, ukazuju na problematičnu pojavu nekoordiniranosti namjere i zaključaka u provedbi eksperimenta, koja predstavlja to da Oliver neke eksperimente počinje s namjerom ispitivanja nekih čimbenika, a završava sa zaključcima o drugim čimbenicima ili sa zaključcima o interakcijskim učincima. Ove poteškoće u održavanju usmjerenosti na ispitivanje određenih učinaka zasigurno su posljedica Oliverove metakognitivne slabosti u praćenju procesa eksperimentiranja i zaključivanja, te njegove opće rastresenosti i brzopletosti u radu koja mu otežava koordiniran i fokusiran pristup. Ipak, te se poteškoće mogu povezati i s Oliverovim nedovoljnim razumijevanjem potrebe analiziranja nezavisnih učinaka svakog pojedinog čimbenika, kao i s njegovim shvaćanjem zadatka kao onog u kojem se utvrđuje stupanj uništenja šuma kod različitih kombinacija čimbenika.

Na kraju, dominaciji nevaljanog zaključivanja u Oliverovom radu tijekom cijelog istraživanja svakako doprinosi značajna teorijska uvjetovanost njegovog zaključivanja, odnosno podrazumijevanje «*da sve utječe i sve je povezano*». Čak i kad njegovi zaključci uzimaju u obzir nalaze prikupljene eksperimentima, ti se nalazi ne tretiraju kao informacije pomoću kojih se može ispitati točnost prethodnih teorija, nego često služe samo kao potvrda ili ilustracija tih teorija. U slučaju kad nalazi ne odgovaraju teorijama, Oliver koristi različite mehanizme zaštite vlastitih teorija - ignorira nalaze prebacivanjem odgovornosti za rezultat na druge čimbenike, selektivno usmjerava pažnju samo na potvrđujuće podatke, mijenja (izmišlja) podatke tako da odgovaraju teoriji, uparuje čimbenik s drugim čimbenikom koji ima kauzalni status. Iako su ovakve tendencije opažene kod svih ispitanika, barem u početnim fazama rada na zadatku, kod Olivera je proces odvajanja teorija i nalaza bio posebno težak i usporen. Otežanosti i sporosti tog procesa vjerojatno je doprinijela i činjenica da su Oliverove teorije o uzrocima uništenja šuma (češće nego teorije drugih ispitanika) bile složene i uključivale interakcijske odnose različitih čimbenika. Kao takve, te su teorije zahtijevale složenije empirijske provjere, koje Oliver sa svojim strateškim i metastrateškim kapacitetima nije bio u stanju izvesti sve do kraja istraživanja.

### ***5.8.2. Značajan napredak u radu na zadatku (Marin i Dea)***

Marin i Dea, kao predstavnici učenika koji su tijekom rada na zadatku istraživačkog učenja ostvarili veliki napredak u valjanosti zaključivanja, te od početne niske razine strateške izvedbe došli do razine koja se smatra uspješnim djelovanjem, predstavljaju posebno zanimljive slučajeve za analizu uvjeta i procesa koji dovode do pojave i jačanja korištenja novih istraživačkih vještina i strategija. Pritom, razlike koje postoje među ovim slučajevima upućuju na mogućnost postojanja različitih putova razvoja, kao i različitih izvora promjena.

Marin je u istraživanje istraživačkog učenja uključen kao predstavnik učenika ispodprosječnog rezultata na Testu nizova i ispodprosječnog interesa za znanost (kao i Oliver). U studiji slučajeva on reprezentira negativnu motivacijsku orijentaciju prema zadatku o uništenju šuma. Tijekom rada na zadatku on daje stabilne i relativno niske<sup>66</sup> procjene interesa za zadatak, vlastite samoefikasnosti i važnosti ostvarivanja uspjeha na zadatku. Te su nepovoljne motivacijske procjene kod Marina uparene s negativnim

---

<sup>66</sup> Iako se Marinove procjene zapravo nalaze na sredini ljestvice, negativnije su od procjena drugih ispitanika.

procjenama emocionalnog stanja i raspoloženja za rad na zadatku, kao i s relativno niskim procjenama namjere ulaganja truda i uloženog truda, te visokim procjenama težine zadatka.

Dein profil je drugačiji. U istraživanje je uključena također na temelju ispodprosječnih sposobnosti induktivnog rezoniranja, ali i na temelju njezinog iznadprosječnog interesa za znanost. U studiji slučajeva ona predstavlja učenicu pozitivne motivacijske orijentacije. Tijekom rada na zadatku daje najviše procjene interesa za zadatak, te visoke procjene važnosti ostvarivanja uspjeha na zadatku i visoke procjene vlastite samoeфикаsnosti. Emocionalno stanje joj je pozitivno, a raspoloženje za rad izrazito veliko. Zadatak o uništenju šuma joj uglavnom nije težak, ipak, u njegovo rješavanje (po vlastitoj procjeni) ulaže dosta truda. Opažanje motivacijskog ponašanja i emocionalnih reakcija tijekom rada na zadatku potvrđuje Deine samoprocjene. Tijekom svih četiri mjerenja Dea djeluje smireno i usredotočeno na zadatak. Ne provodi eksperimente niti prebrzo niti presporo. Prilično je vedra pa se često smiješi, čak i kad njezino predviđanje rezultata eksperimenata odstupa od stvarnih rezultata. Čini se da Dein pozitivan doživljaj situacije učenja predstavlja povoljan kontekst za jačanje njezinih istraživačkih vještina, budući da osigurava održavanje pažnje, ustrajnost i posvećenost potrebnu za uspješan rad na zadatku.

Rješavanje zadatka istraživačkog učenja i Marin i Dea započinju podrazumijevajući njegovim ciljem ostvarivanje pozitivnog rezultata, odnosno *«pomaganje Petru da dođe što prije u školu»*. Osim neprikladnog metakognitivnog razumijevanja cilja zadatka, oboje učenika karakterizira nepostojanje bilo kakve svijesti o postojanju ispravnih strategija eksperimentiranja. Dok Dea na pitanje o potrebnoj strategiji rada odgovara opisujući proceduru rada na zadatku (*«Odabirem sličice tako da kliknem na njih jednim klikom miša i sličice su odabrane»*), Marin uzima u obzir vlastito iskustvo (*«Odabirem ono što mi je logično – što ja nosim u školu»*).

Unatoč istoj razini metakognitivnog znanja s kojom Marin i Dea kreću u rješavanje zadatka o uništenju šuma, praćenje procesa njihovog rada ukazuje na neke sličnosti, ali i neke razlike u njihovim pristupima eksperimentiranju i zaključivanju u pojedinim mjerenjima, kao i na razlike u brzini napredovanja prema razini koja se može smatrati strateškim uspjehom. U nastavku će prvo detaljno biti opisan Marinov, a zatim Dein rad kroz pojedina mjerenja, pri čemu će naglasak biti stavljen na razmatranje uvjeta koji dovode do usvajanja valjanih strategija eksperimentiranja i zaključivanja.

*Marin*

Za razliku od drugih ispitanika koji su u istraživanje ušli uglavnom s jasnim teorijama o postojanju i smjeru utjecaja pojedinih ispitivanih čimbenika, Marin nema čvrsta očekivanja o njima. Kad se, primjerice, radi o čimbeniku 'udaljenost šume od naselja', on kaže: *«Naselja jesu zagađivači šuma, i moguće je da utječu, ali možda u njima žive odgovorni ljudi pa možda i ne mora biti tako»*. Jedini čimbenik o kojem Marin nedvojbeno izražava kauzalnu teoriju jest 'pojava kiselih kiša'.

Nepostojanje jasnih očekivanja o utjecaju čimbenika na uništenje šuma vjerojatno je utjecalo na to da je Marin jedan od rijetkih ispitanika koji istraživanje nije započeo eksperimentom u kojem traži minimalni (ili maksimalni) stupanj uništenja šuma kombiniranjem čimbenika koji, po teoriji, donose takav ishod, već je izabrao neku «slučajnu» kombinaciju. Zapravo, cijelo prvo mjerenje Marin radi potpuno neplanski i nesustavno. Ne samo da redoslijed provedbe eksperimenata unutar tog mjerenja nema neki vidljivi smisao, već Marin uglavnom ne uspijeva izraziti niti smisao provedbe pojedinih eksperimenata. Najviše što može izreći o tome što pokušava pojedinim eksperimentom je *«ovim ispitujem koliko će biti uništenje šuma u ovoj kombinaciji»*. Stoga ne čudi što Marin tijekom prvog mjerenja niti jednom ne uspijeva valjano varirati čimbenike između pojedinih eksperimenata, kao ni valjano interpretirati prikupljene nalaze. Tipičan odgovor koji daje kad kombinacija koju je izabrao dovede do visokog stupnja uništenja šuma je *«Saznao sam da ti svi elementi koje sam ja stisnuo utječu na uništenje šuma»*. Takav odgovor potvrđuje da Marin ne razmišlja o pojedinim čimbenicima, već samo o kombinaciji, kao i to da učinak pridaje kategorijama varijabli, a ne samim varijablama. To potvrđuje i primjer odgovora koji on daje pri interpretaciji rezultata na temelju kombinacije čimbenika koja dovodi do minimalnog uništenja kad kaže: *«Dobio sam da ovo najmanje utječe....To je zbog slabih kiselih kiša i....ne znam...»*.

Iako na Marinov loš učinak zasigurno utječe nedostatno početno metakognitivno razumijevanje cilja i strategija rada na zadatku istraživačkog učenja, kao i izostanak planiranja provedbe eksperimenata i sustavnog eksperimentiranja, opći je dojam istraživačice da je Marinov pristup rada uvelike određen njegovom negativnom motivacijom za rad na zadatku. On djeluje izrazito bezvoljno i nezainteresirano za rad na zadatku, te ostavlja dojam učenika koji je nespreman uložiti bilo kakav napor u razmatranje rezultata eksperimenata koje provodi. Takvoj ocjeni pridonosi opažanje Marinove neverbalne komunikacije, koje pokazuje da on uglavnom sjedi zavaljen ili glave



podbočene na laktove, često zijeva, rasteže se, pokriva usta, sporo govori, trlja oči....Na njegov nemar i nezainteresiranost ukazuje i činjenica da često «griješi» pri odabiru čimbenika za pojedine eksperimente – slučajno klikne na sličice koje ne želi, pa mijenja svoj odabir putem funkcije 'vрати natrag'. Osim toga, na nemotiviranost za rad ukazuje i to što Marin spontano prekida rad na zadatku već nakon petog eksperimenta u prvom mjerenju (uz objašnjenje «*Ne znam....nemam više ideja....*»), pa ostale eksperimente izvodi više da zadovolji istraživačicu, nego da nešto sazna.

U drugom mjerenju Marin je i dalje potpuno nemotiviran za rad (opravdava se glavoboljom i time da mu je dosadno i teško), te nastavlja s neplanskim i nesustavnim radom na zadatku. I dalje učestalo slučajno odabire čimbenike koje ne želi i greškom uključuje pojedine funkcije programa, zabunom predviđa stupanj '5' umjesto namjeravanog stupnja '1'. Ponovno rano prekida rad (već nakon sedmog pokusa), pa u nastavku eksperimente provodi, po vlastitoj izjavi, nasumce. Ti su eksperimenti zapravo bili duplikacija eksperimenata s početka mjerenja, ali to Marin, dakako, nije primijetio.

Ipak, za razliku od prvog mjerenja, u drugom mjerenju Marin napušta potpuno nejasne planove pojedinih eksperimenata i koncentrira se, barem na početku rada, na eksperimentiranje s ciljem generiranja pojedinih ishoda eksperimenata. Počinje s eksperimentom kojim želi pokazati najmanji stupanj uništenja kod bjelogorične šume, pa nastavlja s istom namjerom za crnogorične šume (vidi okvir 3). U sljedeća dva eksperimenta (trećem i četvrtom) pokušava dobiti najviše stupnjeve uništenja kod obje vrste šuma kombinirajući bjelogoričnu šumu s brežuljkastim pojasom i crnogoričnu šumu s nizinskim pojasom (jer, kao i Oliver, smatra da određena vrsta šume odgovara određenom podneblju). Zbunjen manjim stupnjem uništenja kombinacije crnogorične šume i nizinskog pojasa u odnosu na kombinaciju bjelogorične šume i brežuljkastog pojasa, Marin u sljedećem (petom) eksperimentu nastoji, doduše na poticaj istraživačice, provjeriti utječe li konfiguracija tla na uništenje, a pritom eksperiment neplanirano postavlja kao valjani test za čimbenik 'nametnici' (u usporedbi s prvim eksperimentom). Pri donošenju zaključka za taj eksperiment, Marin započinje s interpretacijom na temelju konfiguracije tla, ali uočava nemogućnost tog zaključka («*Ne, ne, nije dobro!*»), pa ispravno opaža da «*Izgleda da su tu utjecali samo nametnici!*». Taj zaključak predstavlja Marinov prvi valjani inkluzivni zaključak, iako nije zabilježeno eksplicitno verbalno osvrtanje na usporedbu eksperimenata s valjano variranim čimbenikom 'pojava nametnika'.

U sljedeća dva eksperimenta (šestom i sedmom), u namjeri ispitivanja toga što najviše od svih čimbenika utječe na uništenje šuma, Marin valjano zaključuje o učinku kiselih kiša na bjelogorične i crnogorične šume. Međutim, u nedostatku motivacije za nastavljanje istraživačke aktivnosti, nakon sedmog eksperimenta Marin želi završiti rad, pa do desetog eksperimenta ne uspijeva više ponoviti uspjeh koji je neposredno prije postigao.

### Okvir 3

Nalazi koje je Marin stvorio tijekom drugog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
2	1	bjelogorica	nizina	daleko	rijetko	nema	1	1
2	2	crnogorica	brijeg	daleko	rijetko	nema	1	1
2	3	bjelogorica	brijeg	blizu	vrlo	ima	4	5
2	4	crnogorica	nizina	blizu	vrlo	ima	5	4
2	5	bjelogorica	nizina	daleko	rijetko	ima	2	3
2	6	bjelogorica	nizina	daleko	vrlo	nema	3	3
2	7	crnogorica	brijeg	daleko	vrlo	nema	3	3
2	8	crnogorica	nizina	blizu	vrlo	ima	5	4
2	9	bjelogorica	brijeg	blizu	vrlo	ima	4	5
2	10	bjelogorica	nizina	daleko	rijetko	ima	2	3

U trećem mjerenju, kao i u drugom, Marinovi zaključci su i dalje uglavnom nevaljani, a tek se povremeno pojavljuje poneki valjani zaključak. Međutim, Marin čini značajan korak naprijed u pristupu koji zauzima na zadatku, tako da se od neplanskog eksperimentiranja pomiče na pristup koji se može okarakterizirati kao lokalno ulančavanje. Njegov rad postaje ponešto reflektivniji i promišljeniji, pa po prvi put Marin počinje koristiti funkciju vraćanja na prethodne rezultate eksperimenata u svrhu povezivanja rezultata različitih eksperimenata i planiranja provedbe sljedećeg eksperimenta. Treće mjerenje je ujedno i prvo mjerenje u kojem Marin spontano premašuje minimum od 10 potrebnih eksperimenata i provodi ukupno 15 eksperimenata. To je vjerojatno povezano i s malim promjenama u motivaciji za rad do kojih dolazi u ovom mjerenju. Iako u treće mjerenje Marin ulazi s istim motivacijskim procjenama kao i u prvom i drugom mjerenju, te tijekom rada pokazuje slično motivacijsko ponašanje kao i ranije, nakon rada na zadatku Marin se osjeća ponešto sigurnijim u sebe i motiviranijim za nastavljanje rada, a daje i za jedan stupanj više procjene interesa za zadatak. Procjenjuje da je pažljivije radio, pa i procjena ostvarenog rezultata i točnosti rješenja raste. Zadatak mu se više ne čini težak i više mu se sviđa, tako da izjavljuje: «*Danas mi je bilo zanimljivije nego prije. Valjda mi je bolji dan...*».

U tom trećem mjerenju Marin prvo izvodi eksperimente u kojima planira pokazati najviši stupanj uništenja bjelogorične i crnogorične šume (vidi okvir 4).

*Okvir 4*

Nalazi koje je Marin stvorio tijekom trećeg mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
3	1	bjelogorica	brijeg	blizu	vrlo	ima	5	5
3	2	crnogorica	nizina	blizu	vrlo	ima	4	4
3	3	bjelogorica	nizina	blizu	vrlo	ima	3	5
3	4	crnogorica	brijeg	daleko	vrlo	nema	3	3
3	5	bjelogorica	nizina	blizu	rijetko	nema	3	1
3	6	crnogorica	brijeg	daleko	rijetko	ima	2	2
3	7	bjelogorica	brijeg	daleko	rijetko	nema	1	1
3	8	crnogorica	nizina	daleko	rijetko	nema	2	1
3	9	crnogorica	brijeg	blizu	vrlo	ima	4	4
3	10	crnogorica	brijeg	daleko	vrlo	nema	2	3
3	11	bjelogorica	nizina	daleko	vrlo	nema	3	3
3	12	bjelogorica	brijeg	blizu	vrlo	ima	4	5
3	13	bjelogorica	brijeg	blizu	vrlo	ima	5	5
3	14	bjelogorica	nizina	daleko	rijetko	ima	4	3
3	15	bjelogorica	nizina	daleko	vrlo	nema	3	3

Zanimljivo je da se ovdje odvija vrlo sličan scenarij kao i u drugom mjerenju. Naime, na temelju vlastite teorije o povezanosti vrste šuma i pojasa u kojem šume rastu, viši stupanj uništenja Marin povezuje s kombinacijom bjelogorična šuma – brežuljkasti pojas i kombinacijom crnogorična šuma – nizinski pojas. Rezultati eksperimenta koji pokazuju manji stupanj uništenja u drugom eksperimentu dovode u sumnju njegovu teoriju o konfiguraciji tla, pa kaže: «*Vidio sam da zapravo ne utječe konfiguracija tla....da baš nije važna... (Što misliš zašto je dobiven manji rezultat?) Zbog konfiguracije tla....Zapravo ne znam, nisam siguran.....*». Rezultati ovog eksperimenta očito zbunjuju Marina, te ga potiču da treći eksperiment postavi tako da bjelogoričnu šumu kombinira s nizinskim pojasom i ostalim čimbenicima koji izazivaju visoki stupanj uništenja šume. Postavljanjem takvog eksperimenta, Marinu je omogućeno donošenje valjanog zaključka i o utjecaju konfiguracije tla (usporedbom prvog i trećeg pokusa) i o utjecaju vrste šume (usporedbom drugog i trećeg pokusa - što Marin nije poduzeo). Iako Marin ne izvještava o tome što namjerava ispitati trećim eksperimentom, očito je da želi provjeriti utjecaj konfiguracije tla, pa u skladu sa svojom teorijom, u ovom eksperimentu očekuje i niži stupanj uništenja (3). Jako se iznenadio kad je uvidio da je stvarni rezultat trećeg eksperimenta zapravo 5, pa je uskliknuo: «*A zašto sada?!?!? Pa... što ne raste ova šuma....Sad mi nešto nije*

*jasno.....pa zar ne uspijeva bjelogorična šuma bolje u nizinama? A-ha, a-ha. Pa ja cijelo vrijeme krivo govorim!...».*

Usmjerenost na razmatranje utjecaja 'konfiguracije tla' i donošenje prvog valjanog ekskluzivnog zaključka skrenulo je Marinovu pažnju na ispitivanje učinka pojedinih čimbenika, pa u narednim eksperimentima pokušava provjeriti utječu li na uništenje šuma kisele kiše, blizina naselja i nametnici. Analiza odabranih kombinacija čimbenika u četvrtom, petom i šestom eksperimentu pokazuje da u tim provjerama Marin kao referentnu vrijednost za usporedbu koristi kombinaciju koja, po njegovoj teoriji, donosi najniži stupanj uništenja šuma (crnogorica – brijeg - daleko od naselja - rijetko padanje kiselih kiša - bez nametnika i bjelogorica – nizina - daleko od naselja - rijetko padanje kiselih kiša - bez nametnika), te da mijenja samo čimbenik koji upravo ispituje. Primjerice, kad ispituje utjecaj blizine naselja, bira kombinaciju bjelogorična šuma – nizina - blizu naselja - rijetko padanje kiselih kiša - bez nametnika i zaključuje: *«Znači naselje ne utječe! (Gdje to vidiš?) To vidim po tome što sam dobio 1 a to je najniže uništenje... ja sam mislio da će utjecati pa sam stavio 3»*. Problem je, međutim, u tome što referentne kombinacije koje donose minimalno uništenje u trećem mjerenju Marin uopće nije izveo, pa zapravo provodi usporedbe s nepostojećim eksperimentom. To, dakako, invalidira njegove zaključke, iako je moguće tvrditi da je Marin u pamćenju pohranio nalaze o minimalnom uništenju.

U sedmom i osmom eksperimentu Marin se ponovno vraća na ispitivanje učinka konfiguracije tla, na jednak način kao što je ispitivao i učinak drugih čimbenika (usporedbom s nepostojećim referentnim eksperimentom). Međutim, učinak konfiguracije tla ispituje zasebno za bjelogoričnu, a zasebno za crnogoričnu šumu, pa se njegov zaključak *«Konfiguracija tla ne utječe niti na jednu vrstu šume»* može shvatiti kao složeni (interakcijski) zaključak. Iako točan, on nije izveden na valjan način, budući da nedostaju dva od četiri eksperimenata nužnih za njegovo donošenje.

U nastavku (u 10. i 11. eksperimentu) Marin na jednak način provjerava interakcijski učinak vrste šume i pojave kiselih kiša, međutim, zaključak je opet točan, ali nevaljano donesen.

Slijed ispitivanja pojedinih čimbenika je nakratko prekinut 12. i 13. eksperimentom, kad Marin namjerno ponavlja jednu «slučajnu» kombinaciju dva puta, u namjeri ispitivanja toga daje li ista kombinacija uvijek isti rezultat. Taj je Marinov postupak izuzetno

zanimljiv, s jedne strane, zato što je jedinstven među svim ispitanicima, a s druge strane, zato što ukazuje da Marin dovodi u pitanje konstantnost ishoda uz pojedine kombinacije čimbenika, čime zapravo propituje mogućnosti postojanja nepouzdanosti mjerenja (koju je realno očekivati u uvjetima pravih istraživanja).

Zanimljivo je napomenuti još i to da Marin tijekom cijelog trećeg mjerenja nije ispitivao niti donosio zaključke o glavnom učinku vrste šume, već je taj čimbenik samo dovodio u vezu s drugim čimbenicima (konfiguracijom tla i kiselim kišama). Stoga Marin završava treće mjerenje bez saznanja o tome utječe li vrsta šume ili ne na uništenje šuma. U razgovoru o teorijama o ovom čimbeniku, na pitanje o učinku ovog čimbenika, on kaže «*Onako, srednje, i utječe i ne utječe....Ne znam....nisam siguran....*».

Marinovo četvrto mjerenje karakterizira još viša razina planiranja provedbe eksperimenata, pa je njegov pristup označen kao djelomično organiziran rad na zadatku. Marin općenito djeluje pomalo zainteresiranije, budnije i usredotočenije na zadatak.

U ovom, zadnjem, mjerenju (okvir 5) Marin sasvim napušta eksperimentiranje s ciljem generiranja pojedinih ishoda eksperimenta, pa tijekom cijelog mjerenja provodi eksperimente s ciljem utvrđivanja učinka pojedinih čimbenika ili ispitivanja interakcijskog učinka dva čimbenika. U odnosu na prijašnja mjerenja, u ovome mjerenju izrazito raste i broj eksperimenata u kojima Marin unaprijed iznosi i neka očekivanja o učinku pojedinih čimbenika na uništenje šuma.

*Okvir 5*  
Nalazi koje je Marin stvorio tijekom četvrtog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
4	1	bjelogorica	nizina	daleko	rijetko	nema	1	1
4	2	crnogorica	nizina	daleko	rijetko	nema	1	1
4	3	bjelogorica	nizina	daleko	vrlo	nema	3	3
4	4	crnogorica	brijeg	daleko	vrlo	nema	3	3
4	5	bjelogorica	nizina	daleko	rijetko	ima	3	3
4	6	crnogorica	brijeg	daleko	rijetko	ima	3	2
4	7	bjelogorica	nizina	daleko	vrlo	nema	3	3
4	8	crnogorica	brijeg	daleko	vrlo	ima	3	4
4	9	crnogorica	brijeg	daleko	vrlo	nema	3	3
4	10	crnogorica	nizina	daleko	rijetko	nema	2	1

U prva dva eksperimenta Marin valjano utvrđuje nepostojanje razlike između bjelogorične i crnogorične šume u kontekstu minimalnog uništenja. Valjano variranje čimbenika

provodi namjerno i svjesno, uz komentar «*Sad ću probati isto to kao u prvom eksperimentu, ali za crnogoricu*». Nakon ispitivanja učinka 'vrste šuma', on ispituje učinak kiselih kiša, te na primjeru bjelogorične šume donosi valjani inkluzivni zaključak o tom čimbeniku. Nakon toga kreće u ispitivanje interakcijskog odnosa vrste šuma i kiselih kiša, namjeravajući ispitati utječu li kisele kiše jednako na crnogoričnu šumu. Međutim, pri konstruiranju zadnjeg potrebnog eksperimenta za donošenje valjanog interakcijskog zaključka, Marin odlučuje crnogoričnu šumu iskombinirati s brežuljkastim pojasom (umjesto da ostavi nizinski pojas koji je bio izabran u ostalim eksperimentima), jer «*crnogorica raste na visini*». Marin pritom ne razumije da mu taj postupak nekontroliranja ostalih varijabli koje nisu dijelom ispitivane interakcije onemogućuje donošenje valjanog zaključka o interakciji vrste šume i kiselih kiša. Potpuno istu pogrešku on radi kod ispitivanja utjecaja pojave nametnika, kad na primjeru bjelogorične šume valjano utvrđuje kauzalni status tog čimbenika, ali ponovno ne uspijeva kontrolirati čimbenik 'konfiguracija tla' i donijeti valjani zaključak o različitom učinku nametnika na crnogoričnu i bjelogoričnu šumu.

U nastavku četvrtog mjerenja Marin se ponovno vraća na ispitivanje učinka kiselih kiša. Iako razloge ponovnog ispitivanja istog čimbenika Marin ne spominje, činjenica, da je pri provjeri koristio iste eksperimente koje je već koristio u prvom ispitivanju tog čimbenika unutar istog mjerenja, sugerira da se radi o njegovoj nepažnji i slabom praćenju procesa eksperimentiranja. Važno je reći da pri tom ponovnom ispitivanju kiselih kiša Marin ponavlja isti obrazac koji je već dva puta pokazao unutar ovog zadnjeg mjerenja, a koji se odnosi na donošenje valjanog jednostavnog zaključka na jednoj vrsti šume, te na pokušaj donošenja složenog zaključka korištenjem druge vrste šuma. Zanimljivo je također napomenuti da je Marin pri konstruiranju eksperimenata za ispitivanje ovog interakcijskog učinka uočio da je pogriješio pri odabiru čimbenika za jedan eksperiment (osmi), kad je zabunom uveo nametnike (među eksperimente bez nametnika), što ga je navelo da odbaci taj eksperiment i u devetom eksperimentu ispravi pogrešku. Nije, međutim, uočio istovrsnu pogrešku korištenja brežuljkastog pojasa među eksperimentima u kojima je izabran nizinski pojas, vjerojatno zato što mu se i dalje činilo teorijski opravdano kombinirati vrstu šume i konfiguraciju tla na određeni način. Stoga je, na kraju, deveti eksperiment završio nevaljanim zaključkom o glavnom učinku kiselih kiša, a deseti eksperiment nevaljanim zaključkom o glavnom učinku konfiguracije tla na primjeru crnogorične šume.

Bez obzira na nedostatke u eksperimentiranju i zaključivanju koji se, prije svega, odnose na nepostojanje konzistentne uporabe valjanih strategija eksperimentiranja i zaključivanja, kao i na nemogućnost izvedbe valjane usporedbe kod interakcijskih učinaka, Marinovo zadnje mjerenje ukazuje na izuzetan napredak u istraživačkom učenju. Napredak na strateškoj razini, međutim, nije bio povezan s jednakim napredovanjem na metastrateškoj razini. Upitan nakon četvrtog mjerenja o strategijama potrebnima za uspješan rad na zadatku istraživačkog učenja u okviru metakognitivnog upitnika, Marin odgovara jednako neprikladnim odgovorom kao i prije početka rada na zadatku: *«Sličice treba birati po nekoj logici. Onako kako osoba misli da je dobro»*. Dok se njegovo iskazano metastrateško znanje zadržava na najnižoj razini, od početka do kraja istraživanja ipak ponešto raste njegovo metakognitivno razumijevanje cilja zadatka, o čemu svjedoči odgovor: *«Cilj je ispitivanja otkriti što najviše utječe na uništenje šuma»*. Premda ovi odgovori ne ukazuje na jasno razumijevanje potrebe usmjerene i kontrolirane usporedbe eksperimenata s ciljem utvrđivanja učinaka pojedinih čimbenika, očito je da je već ovakvo ograničeno razumijevanje zahtjeva zadatka koje je Marin postigao tijekom rada na zadatku bilo dovoljno za pojavljivanje i jačanje valjanog zaključivanja u Marinovom repertoaru istraživačkih vještina.

Također, važno je istaknuti da postizanje veće valjanosti zaključivanja ne vodi nužno postizanju potpunog razumijevanja modela zadatka. Pokazuje se da Marin (uostalom, kao i Dea, što će se vidjeti u nastavku) zanemaruje ispitivanje pojedinih čimbenika ili njezinih razina, pa nema niti mogućnost stjecanja znanja o određenih varijablama. Kategoriju 'često padanje kiselih kiša', primjerice, on nije koristio niti u jednom eksperimentu u drugom, trećem i četvrtom mjerenju. Uz to, u zadnjem mjerenju, kad su mu istraživačke vještine ojačale, propustio je priliku posvetiti se ispitivanju čimbenika 'udaljenost šuma od naselja', pa istraživanje završava sa sljedećom izjavom o tom čimbeniku: *«Ne znam utječe li blizina naselja.....nisam siguran u to.....možda utječe....»*. Može se zaključiti da ograničavanje nalaza koje Marin stvara tijekom rada na zadatku značajno limitira njegovu spoznaju o odnosima ispitivanih varijabli.

### *Dea*

Kao i Marin, Dea na početku rada na zadatku istraživačkog učenja nije usmjerena na ispitivanje pojedinih čimbenika, već ispituje stupanj uništenja šuma kod različitih kombinacija čimbenika. Ponekad kombinacije postavlja tako da dobije određeni stupanj

uništenja (maksimalni ili minimalni), a ponekad nema takvu očitu namjeru, već samo želi, primjerice, *«ispitati to ima li utjecaja vrlo često padanje kiselih kiša i nametnici, sa brežuljkastim područjem i sa udaljenošću od naselja»*. Rezultate često interpretira na temelju opažene razlike između stvarnog stupnja uništenja šuma i stupnja kojeg je ona predvidjela. Tipično objašnjenje toga zašto je ostvaren neki rezultat je sljedeće: *«Ima utjecaja to što je daleko od naselja. To smanjuje uništenje kao i to što je na brežuljkastom pojasu, no problem je to što vrlo često padaju kisele kiše i što postoje nametnici»*. Objašnjenja su često teorijska, a zasnivaju se na zajedničkom pojavljivanju određene razine pojedine varijable i ishoda eksperimenta. Već nakon prvog eksperimenta Dea donosi zaključak. Kad se podaci ne slažu s teorijom, okreće se objašnjenju na temelju drugih čimbenika. Utjecaj pripisuje razini varijable npr. *«ima utjecaj to što je daleko od naselja i to što je na brežuljkastom tlu»* ili *«utjecalo je to što nema kiselih kiša i što nema nametnika»*. Daje mnoštvo zaključaka koji upućuju na kauzalni status pojedinih varijabli (svih!). Već prije desetog eksperimenta smatra da je riješila zadatak, što objašnjava sljedećim riječima: *«Mislim da ne trebam više niti jedan eksperiment napraviti....popunila sam sve stupnjeve....»*

U drugom mjerenju (nalazi su prikazani u okviru 6) dolazi do značajne promjene u pristupu koji Dea zauzima. Naime, eksperimente izvodi s jasnom namjerom generiranja pojedinih ishoda, a pri tome koristi prilično organiziran i sustavan pristup. Iako iz Deino verbalnog protokola nije jasno koliko je «rad po redu» unaprijed planiran i osmišljen, iz eksperimenata koje je provela bilo je očito da je pri provedbi eksperimenata slijedila jedan logičan raspored, od kojeg bi nakratko odustajala tek kad su je dobiveni rezultati eksperimenata odveli u malo drugačijem smjeru. Prvo je pokazala najmanji stupanj uništenja kod bjelogorične šume, pa zatim je pokušala isto kod crnogorične šume. Nakon toga je prešla na što veći stupanj uništenja kod bjelogorične (odabiranjem svih različitih čimbenika u odnosu na kombinaciju s najmanjim uništenjem), pa kod crnogorične šume. Zatim je kroz nekoliko eksperimenata pokušala dobiti osrednji stupanj uništenja, opet kod jedne, pa kod druge vrste šume. Na kraju se ponovno vratila na demonstraciju najmanjeg stupnja uništenja, ovog puta prvo kod crnogorične pa onda i kod bjelogorične šume.

Iako je i u drugom mjerenju Deino eksperimentiranje i zaključivanje i dalje bilo prilično manjkavo, ponajviše zato što nije izvedeno s namjerom ispitivanja učinaka pojedinih čimbenika, kao i zato što je bilo izrazito pod utjecajem njezinih teorijskih razmatranja o kauzalnom učinku svih obuhvaćenih čimbenika, sustavan pristup izvođenja eksperimenata



joj je omogućio da neke susjedne eksperimente izvede na način koji olakšava njihovu valjanu usporedbu. Primjerice, tražeći najviši stupanj uništenja bjelogorične šume, Dea je u trećem eksperimentu drugog mjerenja odabrala kombinaciju te vrste šume s nizinskih pojasom, blizinom naselja, vrlo čestim padanjem kisele kiše i nametnicima. U sljedećem, četvrtom pokusu, tražeći najviši stupanj uništenja crnogorične šume, odabrala je istu kombinaciju čimbenika, osim što je promijenila vrstu šume. Iako je iz verbalnog protokola bilo jasno da Dea nije imala namjeru tim eksperimentima provjeriti razlikuju li se crnogorična i bjelogorična šuma po stupnju uništenja (naime, nije komentirala da mijenja samo vrstu šume, već je svoju namjeru izrazila samo kao «*Sad ću što veći stupanj onečišćenja kod crnogorice*»), nalazi koje je proizvela su joj omogućili da uvidi tu razliku te da je valjano interpretira. Radi se stoga o neosvijestjenom korištenju strategije kontrole varijable i o valjanom inkluzivnom zaključku koji nije intencionalno donesen.

*Okvir 6*  
Nalazi koje je Dea stvorila tijekom drugog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
2	1	bjelogorica	brijeg	daleko	rijetko	nema	2	1
2	2	crnogorica	brijeg	daleko	cesto	nema	2	3
2	3	bjelogorica	nizina	blizu	vrlo	ima	5	5
2	4	crnogorica	nizina	blizu	vrlo	ima	5	4
2	5	bjelogorica	brijeg	blizu	rijetko	nema	3	1
2	6	bjelogorica	brijeg	blizu	vrlo	nema	3	3
2	7	crnogorica	brijeg	blizu	rijetko	ima	2	2
2	8	crnogorica	brijeg	daleko	rijetko	nema	1	1
2	9	bjelogorica	brijeg	daleko	rijetko	nema	1	1
2	10	crnogorica	nizina	daleko	vrlo	ima	4	4

Tijekom ovog drugog mjerenja kod Dee jača i ideja o mogućnosti interakcijskih odnosa među pojedinim čimbenicima, pa, primjerice, u objašnjenju rezultata u tom četvrtom eksperimentu u kojem donosi prvi valjani inkluzivni zaključak, ona iznosi sljedeću misao: «*Mislila sam da će i kod crnogoričnih šuma rezultat biti 5 zbog kiselih kiša jer se u drugom pokusu pokazalo da su dosta osjetljive na kisele kiše. Ali ovdje je sad 4, što znači da na ove šume nešto od ovih uvjeta ne utječe baš kao na crnogoričnu šumu. (Imaš li ideju što bi to moglo biti?) Pa ne znam, možda nisu toliko osjetljivi na nizinski pojas koliko su bjelogorične šume. To bi moglo smanjiti stupanj onečišćenja*». Do kraja drugog mjerenja Dea, međutim, nije iznosila namjeru ispitivanja interakcijskih učinaka, niti je bila sposobna provesti eksperimente koji bi joj omogućili zaključivanje o interakcijskim odnosima.

Treće mjerenje (nalazi prikazani u okviru 7) Dea započinje s idejom da «*sve ima svojeg učinka, iako možda minimalnog, ali ipak učinka koji mijenja stvari*», kao i s namjerom korištenja istog pristupa eksperimentiranja kao u drugom mjerenju. Dea doista i provodi prvi eksperiment tako da pokazuje minimalni stupanj uništenja bjelogorične šume, a pritom koristi sve čimbenike koji, po njezinoj teoriji, nisu ugrožavajući za šume (brežuljkasti pojas, udaljenost od naselja, rijetko padanje kiselih kiša i nema nametnika). Već kod drugog eksperimenta, međutim, ponešto mijenja cilj eksperimentiranja i pomiče se s pokazivanja minimalnog stupnja uništenja kod crnogorice prema ispitivanju učinka vrste šuma. Ona kaže: «*Sad ću to isto pokušati ispitati sa crnogoričnom šumom*», bira iste čimbenike kao u prvom eksperimentu, te postavlja hipotezu o većem stupnju uništenja kod ove vrste šume, na temelju (krivog) sjećanja dobivenih eksperimentalnih rezultata u prethodnom mjerenju. Na temelju valjanog variranja čimbenika 'vrsta šume', te kontroliranja svih drugih čimbenika, Dea donosi valjan ekskluzivan zaključak o tom čimbeniku.

#### Okvir 7

Nalazi koje je Dea stvorila tijekom trećeg mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
3	1	bjelogorica	brijeg	daleko	rijetko	nema	1	1
3	2	crnogorica	brijeg	daleko	rijetko	nema	2	1
3	3	bjelogorica	nizina	blizu	vrlo	ima	4	5
3	4	crnogorica	nizina	blizu	vrlo	ima	4	4
3	5	bjelogorica	brijeg	daleko	vrlo	nema	3	3
3	6	crnogorica	brijeg	daleko	vrlo	nema	2	3
3	7	bjelogorica	brijeg	daleko	rijetko	ima	2	3
3	8	crnogorica	brijeg	daleko	rijetko	ima	2	2
3	9	bjelogorica	brijeg	blizu	rijetko	nema	2	1
3	10	crnogorica	brijeg	blizu	rijetko	nema	2	1
3	11	bjelogorica	nizina	blizu	vrlo	ima	5	5
3	12	crnogorica	nizina	blizu	vrlo	ima	5	4

U trećem i četvrtom eksperimentu ponavlja se obrazac prvog i drugog eksperimenta. U trećem eksperimentu Dea se vraća na pokazivanje maksimalnog stupnja uništenja kod bjelogorične šume, pa bira nizinski pojas, blizinu naselja, vrlo često padanje kiselih kiša i nametnike, dok u četvrtom eksperimentu, imajući za cilj «*ispitati isto to samo kod crnogorične šume*», postavlja točnu hipotezu i valjano utvrđuje razliku u uništenju bjelogorične i crnogorične šume. Dea zaključuje: «*...Znači, sve te najgore stvari crnogorična šuma bolje podnosi od bjelogorične...*». U tom trenutku očito je da Dea

polako počinje uviđati prednost koju joj donosi usporedba eksperimenata za zaključivanje o učinku pojedinih čimbenika, te razmišlja o promjeni strategije rada na zadatku u odnosu na prijašnji pristup eksperimentiranja s ciljem pokazivanja određenog stupnja uništenja šume. O tome svjedoči sljedeći citat: *«Sad bih ispitala srednji stupanj uništenja šuma, ali nekako mi se čini kako sam prošli put radila.....da nisam baš shvatila koliko neke stvari imaju utjecaja.....Sad bih kod osrednjih stupnjeva malo mijenjala da neke stvari budu malo veće, neke malo manje, da vidim koliko što utječe»*. Već u sljedećoj rečenici Dea još jasnije formulira novi pristup postavljajući eksperiment za ispitivanje učinka kiselih kiša: *«Sad pokušavam otkriti koliko svaki od tih čimbenika ima zapravo veze....Sad ispitujem kisele kiše. Sve sam čimbenike stavila na najmanje, a kisele kiše na najviše»*. Na temelju toga, Dea u petom eksperimentu valjano zaključuje o učinku kiselih kiša. U sljedećem (šestom) eksperimentu, ispitujući kako kisele kiše utječu na crnogoričnu šumu, Dea donosi i prvi valjani interakcijski zaključak. Prethodno je postavila interakcijsku hipotezu o nižem stupnju uništenja crnogorične šume u uvjetima postojanja kiselih kiša, u odnosu na bjelogoričnu šumu (*«Mislim da bi se ovdje moglo dobiti da su crnogorične šume malo otpornije i da su malo manje uništene»*), a, zatim, na temelju postignutog identičnog rezultata zaključuje: *«Isto je, znači jednak je utjecaj kiselih kiša i na crnogorične i na bjelogorične šume»*. U sedmom i osmom eksperimentu na jednaki način Dea valjano ispituje glavni učinak nametnika i interakcijski učinak vrste šume i nametnika. U devetom eksperimentu usmjerava se na ispitivanje čimbenika 'udaljenost šuma od naselja', te iako iznenađena, ispravno i valjano zaključuje da *«bjelogoričnoj šumi uopće ne smeta što je blizu naselja»*. U desetom eksperimentu kreće s ispitivanjem interakcijskog učinka blizine naselja i vrste šume, ali joj, vjerojatno zbog neočekivanog rezultata, pažnja skreće s interpretiranja interakcijskog učinka navedenih čimbenika, pa opaženi rezultat interpretira samo kao replikaciju nalaza iz prethodnog eksperimenta: *«Opet je 1. Znači da baš i nema neki utjecaj blizina naselja koliko sam ja mislila, ako postoji samo taj jedan od loših čimbenika.....Ako ih se uzastopno složi više, onda ima neki utjecaj.....»*. Iz navedenog citata je jasno da Dea iz napravljenih eksperimenata zapaža da čimbenik 'udaljenost šume od naselja' nema učinak na uništenje šuma, ali zbog svoje teorije o kauzalnom učinku tog čimbenika, taj joj zaključak «ne sjeda dobro», pa pokušava pomiriti dobivene nalaze i svoju teoriju tako da ograničava zaključak samo na slučajeve niskog uništenja šuma. Takvo ograničavanje zaključka ostavlja prostor za mogući utjecaj blizine naselja u drugim kombinacijama čimbenika, pa joj omogućuje zadržavanje prethodne teorije u neznatno promijenjenom obliku. To se doista i opaža kod Dee, koja se u razgovoru o teorijama

neposredno nakon trećeg mjerenja vraća na kauzalnu teoriju o ovome čimbeniku, pritom čak iskrivljujući prikupljene nalaze: *«Blizina naselja ima nekakav utjecaj, iako ne znam točno za koje šume sam dobila da blizina nije imala toliki utjecaj...Mislim da je to bilo kod crnogoričnih šuma...To baš nije utjecalo mnogo, ali ima utjecaj»*.

Zbunjena neočekivanim rezultatima o učinku blizine naselja, Dea na kraju trećeg mjerenja nesvjesno ponavlja dva eksperimenta koja je već izvela tijekom tog mjerenja, a koja se odnose na maksimalni stupanj uništenja crnogorične i bjelogorične šume. Vjerojatno je tim posljednjim eksperimentima na neki način željela demonstrirati učinak blizine naselja u nepovoljnim kombinacijama čimbenika, međutim, u zaključku se osvrnula samo na glavni učinak 'vrste šume' te ponudila objašnjenje te razlike, koje je već postigla ranije unutar istog mjerenja: *«Crnogorične šume su ipak malo snažnije. Znači ne utječu na njih svi ti drugi čimbenici koliko na bjelogorične šume»*. Tim objašnjenjem Dea je zapravo napravila korak unatrag u odnosu na objašnjenja koja je dala kad je valjano ispitala interakcijske učinke vrste šuma i kiselih kiša i nametnika, ali ga je ponovno upotrijebila kako bi uklopila «neobične» nalaze o nepostojanju učinka blizine naselja.

U četvrtom mjerenju Dea nastavlja donositi valjane inkluzivne, ekskluzivne i interakcijske zaključke, koristeći isti pristup i istu logiku ispitivanja kakvu je usvojila tijekom trećeg mjerenja. Uspoređujući bjelogoričnu i crnogoričnu šumu u situacijama minimalnog, srednjeg i maksimalnog uništenja, potvrđuje glavni učinak 'vrste šume' i interakcijski učinak (odnosno njegovo nepostojanje) tog čimbenika s kiselim kišama i blizinom naselja. Ponovno pokazuje da blizina naselja nema utjecaj niti kod crnogorične ni kod bjelogorične, te ostaje kod objašnjenja: *«Ne smeta šumama blizina naselja...Ako je prisutna samo blizina naselja, a ostalo su najslabiji čimbenici to nema neki utjecaj, ali kad su svi čimbenici spojeni zajedno, onda već ima nekih promjena»*. Jedino novo postignuće zadnjeg mjerenja predstavlja zapravo razumijevanje nelinearnog učinka čimbenika 'kisele kiše', odnosno uočavanje nepostojanja razlike u uništenju šuma između situacija kad kisele kiše padaju često i vrlo često.

Praćenje Deinog procesa istraživačkog učenja kroz četiri mjerenja pokazuje da je ona u trećem i četvrtom mjerenju napravila ogroman napredak u pristupu eksperimentiranju i zaključivanju jer se okrenula ispitivanju učinka pojedinih čimbenika, postavljanju jasnih hipoteza, uporabi strategije kontrole varijable i konzistentnom valjanom zaključivanju o jednostavnih i interakcijskim učincima. Dea postiže i najvišu razinu metakognitivnog razumijevanja cilja zadatka budući da izjavljuje: *«Učenikov cilj je pokušati istražiti kakav*

*utjecaj ima određeni čimbenik na stupanj onečišćenja, te istražiti kakve veze imaju određeni čimbenici jedni s drugima».*

Napredak u istraživačkim vještinama odvijao se kod Dee paralelno s napredovanjem metakognitivnih vještina. Osim što je njezin rad bio sve bolje planiran, organiziran i sustavan, u kasnijim mjerenjima je eksperimente provodila znatno promišljenije i reflektivnije - tijekom rada više se puta referirala na rezultate prošlih eksperimenata i povezivala ih s planovima izvedbe novih eksperimenata, osvrkala se na dostignuta postignuća i potrebu ispitivanja neistraženih čimbenika, komentirala je vlastiti pristup eksperimentiranju, uočavala pogreške u eksperimentiranju i slično. Zanimljivo je, međutim, uočiti da postojanje ovih metakognitivnih aktivnosti nije dovelo do metakognitivne razine koja bi predstavljala potpuno osviještenu promjenu strateškog pristupa i reflektivno korištenje valjanih strategija eksperimentiranja i zaključivanja. O tome svjedoči Dein odgovor na pitanje o korištenom pristupu rada u trećem mjerenju (u kojem je zapravo ostvaren prijelaz na potpuno valjano eksperimentiranje i zaključivanje): *«Nisam mijenjala pristup u odnosu na prošli put, imala sam isto mišljenje – što stavim više tih loših čimbenika, to je veće onečišćenje, a ako stavim bolje čimbenike, to je manje onečišćenje. Osrednje je kad se pomiješa i jednog i drugog».* Unatoč konzistentnoj uporabi strategije kontrole varijable u zadnja dva mjerenja, Dea do kraja istraživanja nije sasvim osvijestila korištenje te strategije. Najviše što je postigla u tome sadržano je u njezinoj rečenici izrečenoj tijekom eksperimentiranja *«Sad ću isto s crnogoričnom šumom i istim čimbenicima».* Međutim, upitana o strategijama potrebnima za rad na zadatku istraživačkog učenja nakon četvrtog mjerenja, u sklopu upitnika metakognitivnog znanja, Dea ne uspijeva dati prikladan odgovor, već se zadržava na proceduralnom opisu postupka rada na zadatku. Iako postoji mogućnost da primijenjena upitnička mjera metastrateškog znanja podcjenjuje stvarnu razinu metakognitivnog razumijevanja nužnosti korištenja strategije kontrole varijabli za zaključivanje o učincima pojedinih čimbenika, analiza Deinog eksperimentiranja i zaključivanja upućuje da ono doista nije postalo potpuno reflektivno i eksplicitno, kao i da korištenje strategije kontrole varijabli nije shvaćeno kao generalizirano pravilo koje se može primijeniti u različitim slučajevima. Primjer ispitivanja učinka čimbenika 'blizina naselja' pokazuje da Dea valjano eksperimentiranje primjenjuje isključivo uspoređujući kombinaciju čimbenika koji dovode do minimalnog uništenja s kombinacijom u kojoj je ispitivani čimbenik, po njezinim riječima, *«pojačan»* (što jest logično jer postojanje stalnog referentnog eksperimenta olakšava usporedbu!), dok

zanemaruje mogućnost ispitivanja učinka tog čimbenika na drugim stupnjevima uništenja šuma. Osim što je jasno da takvom ograničenom usporedbom ona pokušava zaštititi svoju kauzalnu teoriju o blizini naselja, čini se da niti ne razumije u potpunosti da učinak 'blizine naselja' može na jednako valjani način provjeriti na drugim stupnjevima uništenja šuma. Umjesto provjere, ona se radije zadovoljava s izjavom koju više puta ponavlja, a koja naznačuje da *«blizina naselja baš i nema neki utjecaj ako su čimbenici jako mali»*.

Zanimljivo je, također, uočiti da, iako su svi zaključci koje je Dea donijela tijekom trećeg i četvrtog mjerenja bili valjani, to nije bilo povezano s potpunom promjenom u znanjima o odnosima između varijabli. Jedan dio problema leži u činjenici da je Dea ograničila skup napravljenih eksperimenata toliko da, primjerice, tijekom trećeg i četvrtog mjerenja nije provodila eksperimente koji bi joj omogućili donošenje zaključaka o učinku čimbenika 'konfiguracija tla'. Razloge neispitivanja ovog čimbenika Dea je pronalazila u tome što *«već smo prošli put vidjeli rezultate za pojas»*. Bilo je očito da ju je njezina uvjerenost u teoriju koju je imala o ovome čimbeniku priječila u provjeri tih očekivanja i zadržala je u krivom uvjerenju o postojanju kauzalnog učinka ovog čimbenika sve do kraja istraživanja. Slično tome, Dea tijekom trećeg mjerenja nije niti u jednom provedenom pokusu iskoristila kategoriju 'često padanje kiselih kiša', što je onemogućilo testiranje razlike između ove i ostalih kategorija te varijable u tom mjerenju. U četvrtom mjerenju, pak, uopće nije ispitivala nametnike, pa je i njezino razumijevanje učinka tog čimbenika ostalo dijelom netočno.

Drugi dio problema nepovezanosti valjanog zaključivanja i promjena u znanju o kauzalnoj strukturi modela zadatka nalazi se u već opisanoj tendenciji iskrivljavanja nalaza i zaključaka koje je Dea valjano donijela tijekom eksperimentiranja (npr. o učinku čimbenika 'blizina naselja' u trećem mjerenju), u trenutku kad je u razgovoru o vlastitim teorijama trebalo sumirati postignute rezultate. Ta tendencija pokazuje da je Deino zaključivanje još uvijek pod značajnom dominacijom njezinih teorija, ali i ukazuje na nedostatan korištenje metakognitivnih vještina elaboracije i refleksije, koje bi joj pružile mogućnost čvršćeg povezivanja i pohranjivanja postignutih rezultata u pamćenju.

Zaključno, potrebno je reći da usporedba Deinog i Marinovog puta napredovanja prema valjanom eksperimentiranju i zaključivanju kroz četiri situacije istraživačkog učenja ukazuje na mnoge zajedničke elemente. I Dea i Marin započinju rad na zadatku bez prikladnog metakognitivnog razumijevanja zahtjeva zadatka, kao i bez razvijenih metakognitivnih vještina planiranja, praćenja i kontroliranja istraživačkih aktivnosti. Od

prvog do četvrtog mjerenja oboje napreduju od potpuno nesustavnog i neorganiziranog pristupa prema osmišljenijem, analitičkom i samoupravljanom eksperimentiranju. Iako oboje učenika prve valjane zaključke donose u kontekstu provedbe eksperimenata s ciljem pokazivanja određenog stupnja uništenja šuma, a ne intencionalno valjano varirajući ispitivani čimbenik u cilju ispitivanja njegovog učinka, upravo je sustavnost rada i «rad po redu» bio ključan element koji im je omogućio valjanu usporedbu i donošenje prvih valjanih zaključaka. Važnu ulogu u pojavljivanju i jačanju valjanih istraživačkih strategija zasigurno je kod oboje imalo i jačanje metakognitivnog praćenja istraživačke aktivnosti, budući da se valjano eksperimentiranje i zaključivanje često javljalo kao pokušaj dobivanja odgovora na uočene neobične ili neočekivane rezultate eksperimenata.

Usprkos značajnom napredovanju u istraživačkim vještinama i strategijama tijekom rada na zadatku, potrebno je reći da i Dea i Marin završavaju istraživanje s nepotpunim razumijevanjem odnosa između varijabli. Budući da oboje pokazuju sposobnost primjene valjanih istraživačkih strategija, to je posljedica ograničavanja prostora eksperimenata i neproduciranja dovoljnog broja eksperimenata kojima bi testirali i opovrgnuli vlastite teorije. Uz nepotpuno znanje o kauzalnoj strukturi modela zadatka, oboje učenika na kraju istraživanja pokazuju i nedostatno eksplicitno metastrateško znanje, što ukazuje na složen odnos metastrateških i strateških vještina, te potvrđuje da je korištenje i jačanje valjanih istraživačkih pristupa moguće čak i bez jasne refleksije o njihovoj nužnosti i korisnosti.

Na kraju, potrebno je ipak istaknuti da se dosezi Deinog i Marinovog istraživačkog rada značajno razlikuju. Dok Dea do kraja istraživanja uspijeva konzistentno koristiti strategiju kontrole varijable i valjano zaključivati o jednostavnim, pa i interakcijskim učincima čimbenika na uništenje šuma uz 100% uspješnost, Marin se tome cilju tek približava. Njegovu izvedbu na zadatku karakterizira paralelno pojavljivanje i nevaljanih i valjanih usporedbi i zaključaka o učinku pojedinih čimbenika, te postupno jačanje udjela valjanih istraživačkih strategija prema kraju istraživanja. Uz postizanje tek djelomično valjanih jednostavnih zaključaka, Marinov rad karakterizira i nemogućnost dosizanja kvalitativnog skoka kojeg predstavlja donošenje valjanih interakcijskih zaključaka.

Iako tentativno, moguće je opažene razlike u brzini i razini napredovanja prema valjanom eksperimentiranju i zaključivanju između Dee i Marina povezati s razlikama koje među njima postoje u motiviranosti za rad na zadatku, u usredotočenosti za pronalaženje rješenja, spremnosti na ulaganje truda potrebnog za razmatranje rezultata i osmišljavanje novih eksperimenata. Dok su Dein interes za zadatak i pozitivna očekivanja tijekom cjelokupnog

rada na zadatku zasigurno pogodovali njezinoj predanosti radu, koncentriranosti na zahtjeve zadatka te ulaganju truda, može se reći da je Marinovo početno istraživačko učenje obilježio potpuno neproduktivan stav koji ga je priječio u dubljem «uranjanju» u zadatak i zauzimanju istraživačkog fokusa. Tek u trećem mjerenju, kad se Marinovo raspoloženje pomalo popravilo i kad je smanjio vlastita negativna očekivanja, otvorio mu se put napredovanja na zadatku. Ovakvi nalazi upućuju na važnost motivacijskih procesa u istraživačkom učenju, jer pokazuju da negativna motivacija za rad na zadatku može ograničavati učenje tako da usmjerava učenika na (pre)rano završavanje rada i na zauzimanje površnog i neučinkovitog pristupa (npr. nasumičnim/ nesustavnim biranjem kombinacija čimbenika), kao i da pozitivna motivacija može imati facilitirajući učinak i voditi primjeni planski organiziranijeg i sustavnijeg pristupa eksperimentiranju.

### **5.8.3. Visoka razina strateške izvedbe na zadatku (Borna i Iva)**

Borna i Iva predstavljaju učenike koji već na početku rada na zadatku istraživačkog učenja ostvaruju visoku razinu strateške izvedbe i donose većinom valjane zaključke o učincima pojedinih čimbenika na uništenje šuma. Iako oboje spadaju u skupinu uspješnih ispitanika, njihove razine strateške izvedbe nisu sasvim izjednačene<sup>67</sup>. Dok Borna već u prvom mjerenju postiže 85% valjanih zaključaka, Iva donosi tek nešto više od 50% valjanih jednostavnih zaključaka u tom mjerenju. Bez obzira na te razlike, ovi su slučajevi uključeni u kvalitativnu analizu jer ilustriraju različite primjere uspostavljanja i održavanja valjanog zaključivanja u situacijama ponavljanog izlaganja istom zadatku.

Borna je u istraživanje uključen kao predstavnik učenika iznadprosječnih induktivnih kognitivnih sposobnosti, te ispodprosječnog interesa za znanost. U studiju slučajeva je odabran kao učenik kojeg karakterizira negativnija motivacijska orijentacija prema zadatku o uništenju šuma. Analiza Borninih motivacijskih procjena pokazuje da se on našao u ovoj skupini prvenstveno zato što daje relativno niske procjene važnosti ostvarivanja uspjeha na zadatku (koje odgovaraju vrijednosti 3 na ljestvici), dok su mu procjene interesa za zadatak, samoeфикаsnosti i namjere ulaganja truda tijekom svih četiri mjerenja uglavnom pozitivne (odgovaraju vrijednosti 4). Emocionalno stanje i raspoloženje za rad mu je također relativno povoljno i stabilno.

---

<sup>67</sup> Sasvim komparabilne predstavnike skupina učenika pozitivnije i negativnije motivacijske orijentacije nije bilo moguće pronaći. Među učenicima pozitivnije motivacijske orijentacije nije bilo niti jednog ispitanika koji je postizao tako visoke udjele valjanih zaključaka u prvom mjerenju (više od 75%), dok ih je među učenicima negativnije motivacijske orijentacije bilo četiri.



Iva je predstavnica učenika iznadprosječnog interesa za znanost i ispodprosječnog rezultata na Testu nizova. U studiju slučajeva je uključena kao učenica pozitivne motivacijske orijentacije. U sva četiri mjerenja ona daje najviše procjene sviđanja i interesa za zadatak, kao i procjene samoeфикаsnosti, a karakterizira je i visoko raspoloženje za rad i pozitivno emocionalno stanje. Procjene važnosti ostvarivanja uspjeha na zadatku i ulaganja truda su također visoke. Zadatak joj se uopće ne čini težak.

Prije opisa Borninog i Ivinog rada na zadatku o uništenju šuma, valja istaknuti da ovi učenici ne odstupaju od drugih po početnom metakognitivnom razumijevanju cilja i strategija rada na zadatku. Metastrateško znanje im je na nultoj razini, budući da smatraju da čimbenike za pojedine eksperimente treba birati *«lijevim klikom miša»* (Borna) ili *«tako da malo razmislimo i onda kliknemo na sličicu»* (Iva). Ivino razumijevanje cilja zadatka jednako je neprikladno i odgovara razini «0» (*«Ja na tom zadatku trebam rješavati razne i zanimljive zadatke. Svatko radi sam. Ne radimo u grupama. U tim zadacima moramo logički zaključivati i to su općenito istraživački zadaci»*), dok se Bornino razumijevanje podudara s većinskim shvaćanjem zadatka istraživačkog učenja kao onog u kojem treba postići pozitivan ishod (*«Cilj je bio pomoći Petru da ne zakasni u školu - smisliti idealnu formulu»*).

U nastavku je prvo predstavljen Bornin, pa zatim Ivin rad na zadatku o uništenju šuma. Poglavlje završava kratkom usporedbom njihovih rezultata, te sumiranjem glavnih nalaza kvalitativne analize.

### *Borna*

U skladu s vlastitim metakognitivnim razumijevanjem cilja zadatka, Borna započinje prvo mjerenje traganjem za idealnom kombinacijom čimbenika, onom koja dovodi do minimalnog uništenja (okvir 8). Prvi eksperiment postavlja odabirući čimbenike koji po njegovim očekivanjima donose takav povoljan ishod, međutim, krivo shvaća značenje sličica za čimbenik 'pojava nametnika', pa umjesto namjeravane sličice 'bez nametnika', bira onu 'ima nametnika'. Prvi eksperiment stoga završava sa stupnjem uništenja 2, pa Borna, ponovno tražeći idealnu kombinaciju, u drugom eksperimentu ispravlja pogrešku, te ujedno mijenja vrstu šume i konfiguraciju tla. Kad se pokazalo da je stvarni rezultat ovog eksperimenta bio 1, Borna je veselo uskliknuo: *«Jedan! Znači, ovo je idealna kombinacija – bjelogorično drveće, ravnica, daleko od naselja, malo kiselih kiša i nema*

štetnika!». Smatrao je da je pronalaskom idealne kombinacije riješio zadatak te je ovime namjeravao završiti rad na njemu.

### Okvir 8

#### Nalazi koje je Borna stvorio tijekom prvog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
1	1	crnogorica	brijeg	daleko	rijetko	ima	2	2
1	2	bjelogorica	nizina	daleko	rijetko	nema	2	1
1	3	bjelogorica	brijeg	blizu	vrlo	ima	4	5
1	4	crnogorica	nizina	daleko	rijetko	nema	1	1
1	5	crnogorica	brijeg	daleko	rijetko	nema	2	1
1	6	bjelogorica	nizina	blizu	rijetko	nema	2	1
1	7	crnogorica	brijeg	daleko	cesto	nema	2	3
1	8	crnogorica	brijeg	daleko	vrlo	nema	4	3
1	9	bjelogorica	nizina	blizu	rijetko	ima	3	3
1	10	crnogorica	nizina	blizu	vrlo	ima	5	4
1	11	bjelogorica	nizina	daleko	vrlo	ima	4	5

Kad mu je ponovno pojašnjeno da će nakon rada na zadatku biti pitan ima li ili nema svaki pojedini čimbenik učinak na uništenje šuma, nastavlja s trećim eksperimentom. Taj eksperiment izvodi bez jasnog plana, samo da nekako nastavi. Kao rezultat takvog neusmjerenog ispitivanja, na temelju usporedbe prvog i trećeg eksperimenta, donosi nevaljani zaključak o učinku jednog čimbenika (vrste šume).

Međutim, nakon trećeg eksperimenta dolazi do naglog zaokreta u pristupu koji Borna zauzima u eksperimentiranju. U sljedećim eksperimentima potpuno se okreće ispitivanju učinka pojedinih čimbenika i valjanom eksperimentiranju i zaključivanju.

Uzimajući drugi eksperiment (idealnu kombinaciju) kao referentni eksperiment, prvo donosi valjani ekskluzivni zaključak o vrsti šuma. Pritom, pri izvođenju eksperimenta Borna vrlo jasno elaborira i iznosi svoja očekivanja, što upućuje na kvalitetnu uporabu metakognitivnih vještina već na početku istraživanja. Borna kaže: *«Sad ispitujem hoće li i ovdje biti 1. Ako tu ispadne 1, onda ćemo vidjeti da je uništenje jednako i da zapravo nije važno koja je šuma. Ja ću i predvidjeti da će biti 1, dakle isto!»*.

U nastavku (od petog do devetog eksperimenta) na podjednako promišljen i refleksivan način, Borna koristi strategiju kontrole varijable i donosi valjane zaključke o glavnim učincima ostalih čimbenika. Pritom izjavljuje: *«Sad mi postaje zanimljivije!»*.

Eksperimente radi po redu prezentacije čimbenika u programu i do kraja ne odstupaju od planiranog slijeda eksperimenata. Nakon zaključka o učinku vrste šume, donosi zaključak o konfiguraciji tla, pa o blizini naselja, pa o pojedinim stupnjevima kiselih kiša, pa na kraju i o nametnicima. U ispitivanjima učinka pojedinih čimbenika, kombinacije bira oslanjajući se na referentni eksperiment idealne kombinacije, ali u nekim eksperimentima mijenja kategorije vrste šume (i konfiguracije tla) jer *«to sam pokazao da nema veze»*. Svaki eksperiment izvodi s jasno izrečenom namjerom (npr. *«Sad ćemo vidjeti je li bolja ravnic ili brda»*), a prije dovršavanja pojedinog eksperimenta iznosi hipoteze o učinku čimbenika čiji učinak upravo ispituje. Kad postavlja eksperiment ili donosi zaključak, često ponavlja dotad utvrđene nalaze, čime se potvrđuje da konstantno metakognitivno prati i kontrolira proces učenja.

Nakon devetog eksperimenta Borna se vraća na početni pristup i želi *«probat i vidjeti koja je najgora kombinacija»*. Odabire crnogoričnu šumu u nizinskom pojasu, blizu naselja, uz vrlo česte kisele kiše i nametnike, pa je rezultat eksperimenta bio 4. Borna je začuđen i iznenađen tim rezultatom, pa se duže zadržava na ovom eksperimentu. Iako je bilo očito da razmišlja, nije ništa rekao, osim: *«Zašto sada 4?»*. U sljedećem, zadnjem eksperimentu prvog mjerenja, uspijeva dobiti najviši stupanj uništenja šuma s kombinacijom bjelogoričnice - daleko od naselja - vrlo čestim kiselim kišama - s nametnicima. Na temelju usporedbe zadnja dva eksperimenta, Borna donosi prve interakcijske zaključke. Zaključuje sljedeće: *«Sad je ispalo 5. To znači da...bjelogorična šuma ima utjecaj jedino kad ima nametnika. Kad je crnogorična šuma, onda nema utjecaj kad ima nametnika... I ovu tu šumu (bjelogoričnu) više uništavaju kisele kiše nego ovu šumu (crnogoričnu)...Zapravo je sve međusobno povezano! (Kako znaš da bjelogoričnu šumu više uništavaju nametnici i kisele kiše?) Zato jer je tu 4, a ovdje je 5!»*. Dakako, radi se o nevaljanim interakcijskim zaključcima, budući da četiri (odnosno šest) eksperimenata potrebnih za valjane zaključke ove vrste nisu provedena.

Drugo mjerenje Borna provodi uspješno kao i prvo. Radi planski i sustavno, međutim, zapaža se manje izjava koje svjedoče o postojanju različitih metakognitivnih aktivnosti, vjerojatno zato što zadatak postaje za Bornu lagan i izvediv bez jačeg angažiranja kontrolnih (metakognitivnih) mehanizama.

Prvim eksperimentom drugog mjerenja Borna pokazuje idealnu kombinaciju, nakon koje provodi eksperimente s ciljem utvrđivanja učinka svakog pojedinog čimbenika. Pritom, valjano varira čimbenike, iznosi hipoteze, i koristeći prvi eksperiment kao usporedni,

valjano utvrđuje glavne učinke svih čimbenika. To, kao i u prvom mjerenju, čini po redu prezentacije čimbenika u programu. U ovom mjerenju Borna donosi i prvi valjani interakcijski zaključak, koji se odnosi na nepostojanje različitog djelovanja kiselih kiša ovisno o vrsti šume. Borna pritom objašnjava: *«Mislio sam da kisele kiše imaju više utjecaja na ovu vrstu šume (bjelogoričnu), a dobio sam jednaki rezultat. Znači da vrsta šume i količina kiselih kiša nisu povezane, da kiše djeluju jednako».*

Na kraju drugog mjerenja (isto kao u prvom mjerenju), Borna se, nakon kratkog razmišljanja i vraćanja na prethodne rezultate eksperimenata, usmjerava na demonstriranje najgore kombinacije. To i postiže kombiniranjem bjelogorične šume s nizinskim pojasom, blazinom naselja, vrlo čestim kiselim kišama i nametnicima. Kao rezultat tog eksperimenta, Borna iznosi pretpostavku o postojanju interakcijskog učinka vrste šuma i nametnika pa kaže *«Moram još provjeriti, ali mislim da nametnici više utječu na bjelogoričnu šumu. (Na temelju čega to kažeš?) Tako mi se čini».* U zadnjem eksperimentu mijenja vrstu šume i donosi interakcijski zaključak o učinku vrste šume i nametnika: *«Nema veze koja je vrsta šume, osim u slučaju kad ima nametnika».* Ovaj je zaključak točan i temeljen na valjanim usporedbama crnogorične i bjelogorične šume u situacijama bez nametnika i u situacijama sa nametnicima. To su sljedeće usporedbe:

5. eks: crnogorična šuma - brežuljkasti pojas - daleko od naselja - vrlo često kisele kiše - bez nametnika

6. eks: bjelogorična šuma - brežuljkasti pojas - daleko od naselja - vrlo često kisele kiše - bez nametnika

i

9. eks: bjelogorična šuma - nizinski pojas - blizu naselja - vrlo često kisele kiše - s nametnicima

10. eks: crnogorična šuma - nizinski pojas - blizu naselja - vrlo često kisele kiše - s nametnicima

Ipak, doneseni interakcijski zaključak o vrsti šume i nametnicima ne može se smatrati valjanim, jer u sva četiri eksperimenta nisu kontrolirani čimbenici 'konfiguracija tla' i 'udaljenost šume od naselja'. Može se, doduše, tvrditi da je Borna tijekom mjerenja donio valjane ekskluzivne zaključke o ovim čimbenicima, što mu je omogućilo da ih varira bez ugrožavanja kvalitete zaključka o drugim čimbenicima. Ipak, zbog postojanja mogućnosti da ovi nekontrolirani čimbenici imaju različit učinak ovisno o razinama drugih varijabli, ovakvo izvođenje interakcijskih zaključaka nije smatrano valjanim.

Izvođenjem 100% valjanih zaključaka o jednostavnim učincima svih čimbenika, te točnim utvrđivanjem interakcijskih učinaka, Borna završava drugo mjerenje s potpunim

razumijevanjem odnosa između varijabli u modelu zadatka. Jača i metastrateško razumijevanje, budući da njegova izjava o korištenom pristupu upućuje na razumijevanje potrebe ispitivanja učinka pojedinog čimbenika variranjem jednog čimbenika u jednom trenutku: *«Radio sam jedan po jedan čimbenik. Krenuo sam s najboljom kombinacijom pa onda s najgorom i ispitivao djelovanje nekih čimbenika na nešto»*.

U trećem mjerenju dolazi do malog nazadovanja u kvaliteti eksperimentiranja i zaključivanja u odnosu na prethodno mjerenje, koje se može povezati s manjom pažljivošću i (pre)velikom brzinom rada koju Borna pokazuje tijekom tog mjerenja. Iako procjene motivacije i emocionalnog stanja ne govore o promjenama koje bi mogle ukazivati na drugačiji odnos prema zadatku (osim što još više pada procjena važnosti ostvarivanja uspjeha na zadatku, koja se sad nalazi na negativnom dijelu ljestvice), dojam je istraživačice da Borni rad na zadatku više ne predstavlja izazov, zbog čega mu pristupa više «rutinski» i površno, bez posebnog udubljenja i promišljanja prikupljenih nalaza. Borna u ovom mjerenju izvodi mnogo pokusa (19), brzo ih izmjenjuje i po prvi put neke pokuse neplanirano ponavlja u potpuno istom obliku, a neke pokuse izvodi pogrešno (ne onako kako je želio). Njegov rad i u ovome mjerenju karakterizira većim dijelom dobro organizirano i sustavno eksperimentiranje, koje je izvedeno sličnim principom kakav je primijenjen i u ranijim mjerenjima. Borna počinje od najgore kombinacije čimbenika, a zatim, po njegovom iskazu, *«proba mijenjati jedan po jedan čimbenik da vidim utječu li»*. Te se strategije, međutim, ne pridržava pri ispitivanju učinka konfiguracije tla i udaljenosti šume od naselja, budući da jednim eksperimentom, u kojem mijenja oba čimbenika, želi demonstrirati nepostojanje njihovog učinka na uništenje šuma. Takvu pogrešku uparivanja (zajedničkog mijenjanja) kategorija konfiguracije tla i blizine naselja ponavlja još jednom i ponovno donosi nevaljani ekskluzivni zaključak o učinku konfiguracije tla. Nakon utvrđivanja glavnih učinaka svih čimbenika i donošenja valjanog interakcijskog zaključka o vrsti šume i pojavi kiselih kiša (između kategorija 'često' i 'vrlo često'), Borna izvodi 12. eksperiment s ciljem pokazivanja idealne kombinacije, nakon čega se ponovno vraća na provjeru učinka pojedinih čimbenika, prije svega konfiguracije tla i udaljenosti šuma od naselja. U tom drugom dijelu mjerenja on gubi ponešto od sustavnosti koju je usvojio već u prvom mjerenju, pa je slijed njegovih istraživačkih namjera ponešto teže pratiti. Iako do kraja mjerenja nastavlja s donošenjem valjanih zaključaka, skretanje s «rada po redu» i slabljenje metakognitivnog praćenja rezultata eksperimenata je dovelo i do pada u rezultatu na razgovoru o teorijama provedenom neposredno nakon trećeg mjerenja. Borna tad izriče

staru teoriju o manjoj otpornosti bjelogoričnih šuma na nametnike, blizinu naselja i kisele kiše u odnosu na crnogorične šume. Borna je smetnuo s uma da je tijekom ovog mjerenja utvrdio jednak stupanj uništenja crnogorične i bjelogorične šume u situaciji čestog i vrlo čestog padanja kiselih kiša, te je izmislio nalaze o interakciji vrste šume i ostala dva čimbenika, budući da ih nije niti ispitivao tijekom ovog mjerenja.

Četvrto mjerenje je po mnogim elementima bilo slično prethodnom. Prevladavaju valjani zaključci, ali nije postignut 100% uspjeh. Borna opet eksperimentira žurno i izvodi mnogo eksperimenata (20), u slijedu koji se može okarakterizirati kao djelomična organizacija. U drugom dijelu mjerenja, ponavlja čak pet eksperimenata iz istog mjerenja, jedan eksperiment čak tri puta!

Prva dva eksperimenta (kao i četiri zadnja eksperimenta) posvećuje pokazivanju najbolje i najlošije kombinacije čimbenika, a zatim prelazi na ispitivanje pojedinih čimbenika. Za razliku od redosljeda koji je prije zauzimao, u ovom mjerenju čimbenike nije ispitivao po redu prezentacije u programu, nego po tome koliko je smatrao da pojedine učinke još treba ispitati (*«Blizinu naselja neću ni ispitivati zato što sam utvrdio da to nema veze»*). Značajan broj eksperimenata posvetio je ispitivanju interakcijskih učinaka. Prvo se usmjerio na ispitivanje učinka kiselih kiša, na jednoj pa na drugoj vrsti šuma, na temelju čega je donio valjane inkluzivne, ekskluzivne i interakcijske zaključke. Nakon toga se usmjerio na ispitivanje učinka nametnika. Isprva je donio valjani inkluzivni zaključak na bjelogoričnim šumama, pa je u sljedećem eksperimentu, koristeći kombinaciju crnogoričnih šuma, točno, ali nevaljano (zbog nekontroliranja čimbenika 'udaljenost šume od naselja') utvrdio interakcijski učinak nametnika i vrsta šuma. Odmah je uočio tu pogrešku, pa je već u sljedećem eksperimentu donio i valjan interakcijski zaključak o vrsti šuma i nametnika.

Insistiranje na ispitivanju interakcijskih učinaka i provjera jednostavnih učinaka osigurali su Borna točne i valjane podatke o učincima pojedinih čimbenika na uništenje šuma. U završnom razgovoru o teorijama učenika, Borna daje sve točne odgovore i ispravno otkriva sve glavne i interakcijske učinke.

Visoko postignuće na zadatku istraživačkog učenja povezano je kod Borne i s promjenama u metakognitivnom znanju o cilju i strategijama rada za zadatku. Nakon rada na zadatku Borna postiže razumijevanje o potrebi utvrđivanja utjecaja različitih čimbenika na uništenje šuma, budući da odgovara: *«Cilj rada na zadatku o uništenju šuma je u detalje*

*otkriti koji čimbenici imaju ikakvog utjecaja na stupanj uništenja šuma. Treba otkriti najbolju i najgoru kombinaciju». Iako Borna izrijeком ne spominje usmjeravanje na ispitivanje svakog pojedinog čimbenika i kontroliranje utjecaja svih ostalih čimbenika, odgovor o potrebnih strategijama rada na zadatku istraživačkog učenja sugerira postizanje te najviše razine: «Ja bih prijatelju predložio da pokuša prvo sam smisliti najbolju kombinaciju, pa onda najgoru kombinaciju. Kada to napravi, predložio bih mu da krene mijenjati čimbenik po čimbenik, te da pamti promjene».*

*Iva*

Za razliku od Borne, koji pokazuje gotovo potpuno valjano zaključivanje i ostvaruje svoj maksimum na zadatku već u drugom mjerenju, Iva pokazuje sporiji put prema tome cilju.

Kao i mnogi ispitanici, Iva započinje eksperimentiranje odabirom kombinacije čimbenika koji po njezinoj teoriji donose malo uništenje šuma. Drugi eksperiment postavlja kao suprotnost prvome i bira različite kategorije u svim varijablama. Na temelju tog jednog eksperimenta i zajedničkog pojavljivanja bjelogorične šume i visokog uništenja donosi (nevaljani) zaključak: *«Bjelogorične šume su sigurno manje otporne od crnogoričnih, ali mogu to vidjeti ovako...Samo ću zamijeniti ove prve šume (op.a. crnogorične šume iz prvog eksperimenta) s bjelogoričnima pa da vidim kako će biti».* Ovaj citat sugerira da Iva već na početku rada na zadatku pokazuje određeno razumijevanje nemogućnosti donošenja sigurnog zaključka na temelju nekontrolirane usporedbe, te da uviđa potrebu variranja pojedinog čimbenika za zaključivanje o njegovom učinku. Treći eksperiment Iva doista i provodi tako da mijenja samo vrstu šume, a ostale čimbenike zadržava kao u prvom eksperimentu, što joj omogućuje donošenje valjanog ekskluzivnog zaključka o vrsti šume. Zanimljivo je, također, da Iva razumije da postoji mogućnost različitog djelovanja tog čimbenika na drugim razinama ostalih varijabli, o čemu govori njezin zaključak: *«Dakle, bjelogorične i crnogorične šume su jednako otporne, barem po ovome – ako su obje udaljene od naselja, ako su na brežuljku, ako ima malo kiselih kiša i nema nametnika».* Valjano eksperimentiranje i zaključivanje Iva nastavlja u sljedeća dva eksperimenta kad donosi valjane ekskluzivne zaključke o konfiguraciji tla, prvo na primjeru bjelogorične, a onda na primjeru crnogorične šume, no već u nastavku posustaje i na temelju nekontroliranih usporedbi donosi nevaljane inkluzivne zaključke o učinku blizine naselja, kiselih kiša i nametnika. Razmatrajući u nastavku ideju o zajedničkom (aditivnom) učinku kiselih kiša i nametnika po kojoj *«oni zajedno utječu jače»*, Iva se vraća na valjano

testiranje učinka nametnika i kiselih kiša. Namjerava iste učinke ispitati prvo na bjelogoričnoj, pa onda na crnogoričnoj šumi, što je dovodi i do dva valjana interakcijska zaključka: *«Kisele kiše utječu isto na obje vrste šuma»* i *«Crnogorične šume su otpornije na nametnike»*.

Rezultati prvog mjerenja pokazuju da je Iva već na početku istraživanja sposobna izvesti valjane usporedbe i zaključke, čak i kad se radi o složenim, interakcijskim učincima, ali i to da nije konzistentna u primjeni valjanog eksperimentiranja i zaključivanja, u situacijama kad očekuje postojanje kauzalnih učinaka ispitivanih čimbenika. Također se pokazuje da Iva jasno razdvaja nalaze koje je stvorila od vlastitih teorija o učinku pojedinih čimbenika, čime pokazuje zavidnu razinu razumijevanja izvora znanja. O tome svjedoči njezina izjava o učinku konfiguracije tla koju daje tijekom razgovora o teorijama nakon prvog mjerenja: *«Izgleda da ne utječe ako je šuma na brežuljku ili na ravnom tlu...Ali ja mislim da to nije tako....Ako pada puno kiselih kiša, ako su poplave, na ravnom se tlu može nataložiti voda koja uništava biljku iznutra, a s uzbrdice voda ode dolje...Eksperimenti to nisu potvrdili, ali ja to mislim, jer smo na prirodi učili o tome kad smo učili o šumama»*.

Pri radu Iva djeluje ozbiljno, smireno i koncentrirano. Detaljno elaborira svoje nalaze i vlastita očekivanja i međusobno ih povezuje, ponavlja i objašnjava. Tek povremeno vidljiva je mala nesigurnost koja se očituje u mijenjanju odabira čimbenika za pojedine kombinacije ili u kolebanju oko toga što sljedeće ispitati. Iz Ivinog je verbalnog protokola jasno da u prvom mjerenju nema jasnog, unaprijed osmišljenog plana eksperimentiranja, pa je njezin rad okarakteriziran kao lokalno ulančavanje, budući da sljedeće eksperimente većim dijelom osmišljava na temelju rezultata prethodno provedenog eksperimenta. Tek jednom daje izjavu koja sugerira da planira slijed nekih eksperimenata unaprijed. Pritom kaže: *«Sad ću provjeriti utjecaj kiselih kiša bez nametnika na bjelogorici, a provjerit ću to kasnije i za crnogoricu»*, a tog se plana i pridržavala.

U drugom mjerenju je planiranje slijeda eksperimenata znatno uočljivije, iako se i u ovom mjerenju Ivi događa da joj rezultati pojedinih eksperimenata skrenu pažnju na ispitivanje drugih čimbenika od namjeravanih. Na početku ovog mjerenja Iva izvodi četiri eksperimenata na bjelogoričnoj šumi, u kojima mijenja čimbenike 'konfiguracija tla', 'nametnici' i 'kisele kiše' (okvir 9). Pod utjecajem vlastite teorije o utjecaju i zajedničkom djelovanju nametnika i kiselih kiša, u eksperimentima povezuje kategorije rijetko padanje kiselih kiša – nema nametnika i kategorije vrlo često padanje kiselih kiša – ima nametnika. Dakako, taj joj postupak onemogućuje donošenje valjanih zaključaka o učinku ovih



čimbenika, ali to Iva ne zapaža. Uz smiješak zaključuje: *«Pet je zbog kiselih kiša i nametnika. Tu gore je bilo rijetko padanje kiselih kiša i bez nametnika pa je bilo jedan, a tu je prisutno i jedno i drugo pa više šteti»*. Istovremeno, u istim eksperimentima ona valjano varira konfiguraciju tla i donosi dva valjana zaključka o ovom čimbeniku.

#### Okvir 9

Nalazi koje je Iva stvorila tijekom drugog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
2	1	bjelogorica	nizina	blizu	rijetko	nema	3	1
2	2	bjelogorica	nizina	blizu	vrlo	ima	4	5
2	3	bjelogorica	brijeg	blizu	rijetko	nema	0	1
2	4	bjelogorica	brijeg	blizu	vrlo	ima	5	5
2	5	crnogorica	nizina	blizu	rijetko	nema	1	1
2	6	crnogorica	nizina	blizu	vrlo	ima	5	4
2	7	crnogorica	nizina	blizu	rijetko	ima	4	2
2	8	crnogorica	nizina	blizu	vrlo	nema	3	3
2	9	crnogorica	brijeg	blizu	rijetko	nema	1	1
2	10	bjelogorica	nizina	daleko	rijetko	nema	1	1
2	11	bjelogorica	brijeg	daleko	rijetko	nema	1	1
2	12	bjelogorica	nizina	daleko	vrlo	ima	5	5
2	13	bjelogorica	nizina	blizu	vrlo	ima	5	5
2	14	crnogorica	nizina	blizu	vrlo	ima	5	4
2	15	bjelogorica	brijeg	blizu	vrlo	ima	5	5
2	16	crnogorica	brijeg	blizu	vrlo	ima	4	4

Od petog eksperimenta nadalje Iva ima namjeru isto ponoviti na crnogoričnim šumama. Međutim, niži stupanj uništenja crnogorične šume u kombinaciji čimbenika koji rezultiraju visokim uništenjem je upućuje na postojanje interakcije vrste šume i nametnika pa nakratko odustaje od ispitivanja učinka konfiguracije tla te se usmjerava na ispitivanje nametnika i kiselih kiša s ciljem *«Želim vidjeti uništavaju li ovu šumu više kisele kiše ili nametnici»*. U toj namjeri sedmi eksperiment postavlja u kombinaciji rijetke kisele kiše - ima nametnika, a osmi u kombinaciji vrlo česte kisele kiše - nema nametnika. Iva ispravno zaključuje da *«crnogoričnu šumu više uništavaju kisele kiše nego nametnici»*, ali i to da *«nametnici manje uništavaju crnogoričnu šumu, a bjelogoričnu više, dok kisele kiše uništavaju sve šume jednako»*, za što nema uporišta u podacima (nema svih četiri valjano variranih eksperimenata), pa su ti interakcijski zaključci označeni nevaljanima.

Nakon ovih zaključaka, Iva se vraća na ispitivanje konfiguracije tla, pa valjano utvrđuje nepostojanje razlike u uništenju šuma između brežuljkastog i nizinskog pojasa i kod crnogorične i kod bjelogorične šume.

Od 12. od 16. eksperimenta Iva odabire kombinacije koje uključuju vrlo često padanje kiselih kiša i nametnike. Ponovno ispituje *«koliko zajedno zagađuju nametnici i kisele kiše»* i ponovno (dvaput) donosi nevaljani interakcijski zaključak o vrsti šume i nametnicima. Još se jednom vraća i na ispitivanje konfiguracije tla, pa donosi valjan jednostavan i interakcijski zaključak o učinku ovog čimbenika i vrsta šuma.

Iz prikaza provedenih eksperimenata u drugom mjerenju može se vidjeti da Iva nastavlja s donošenjem i valjanih i nevaljanih zaključaka, kao i to da se ona više puta vraća ispitivanju istih čimbenika. Ona to interpretira potrebom *«da provjeri još jednom ima li to ili nema veze»* i *«da se uvjerim»*. No, osim poduzimanja ponovnih testiranja s namjerom čiste provjere rezultata, jasno je da Iva te ponovne provjere provodi na različitim razinama drugih varijabli (kod bjelogorice, pa kod crnogorice, kod niskog uništenja, pa kod visokog uništenja). Po tome što očito pretpostavlja mogućnosti postojanja razlika u učincima pojedinih čimbenika ovisno o razinama drugih čimbenika, te po tome što provodi višestruko testiranje istih učinaka, Iva je prilično jedinstvena i napredna među drugim ispitanicima.

Dakako, brojnost provjera koje provodi predstavljaju opterećenje za kapacitete pamćenja i donose problem praćenja rezultata provedenih eksperimenata. Iva to pokušava riješiti tako da ponekad tijekom rada naglas ponavlja dotad donesene zaključke (kako bi ih bolje zapamtila), te se pri radu često vraća na rezultate prethodnih pokusa. Iako time pokazuje značajnu razinu korištenja metakognitivnih vještina praćenja istraživačkih aktivnosti, Iva do kraja mjerenja ne uspijeva održati tu kontrolu, pa nesvjesno ponavlja tri eksperimenta koja je već provela, a pomalo se i gubi među podacima (*«Potvrdilo mi se u prijašnjem mjerenju...U 6. pokusu?.....Ne znam gdje se potvrdilo! Negdje na početku....»*).

U nastavku rada na zadatku, u trećem i četvrtom mjerenju, Iva izvodi veliki broj eksperimenata, ukupno 37. Namjeru što šireg pokrivanja prostora eksperimenata ona objašnjava ovako: *«Da imam više vremena, probala bih sve!»*.

U ovim mjerenjima Iva ponovno napreduje u razini planiranja rada na zadatku, pa se može utvrditi da eksperimente provodi prema općem planu – prvo ispituje učinak pojedinih čimbenika na bjelogoričnoj šumi, pa onda učinak tih čimbenika na crnogoričnoj šumi. Iva svoj plan u četvrtom mjerenju izrijekom i opisuje: *«Prvo ću na bjelogoričnoj šumi provjeriti ima li vrsta tla utjecaja na uništenje, a zatim ću redom provjeriti sve ostale čimbenike»* i *«Sad ću sve isto što sam napravila na bjelogorici provjeriti na crnogorici»*.

Pritom, ispitivanje svake vrste šume započinje određivanjem kombinacije koja donosi minimalno uništenje, nakon čega učinak pojedinih čimbenika utvrđuje usporedbom s početnih eksperimentom, po redosljedu koji je zadan poretkom u programu FILE (vidi okvir 10). Značajan broj eksperimenata Iva posvećuje ispitivanju čimbenika 'kisele kiše' i 'nametnici', tako da rotira kategorije ovih čimbenika. Provjeru učinka pojedinih čimbenika na određenoj vrsti šuma završava biranjem kombinacije koja uključuje vrlo često padanje kiselih kiša i postojanje nametnika, nakon čega prelazi na drugu vrstu šuma.

#### Okvir 10

Nalazi koje je Iva stvorila tijekom četvrtog mjerenja

Redni broj mjerenja	Redni broj eksperimenta	Vrsta šume	Konfiguracija tla	Udaljenost od naselja	Kisele kiše	Pojava nametnika	Predviđeni rezultat	Stvarni rezultat
4	1	bjelogorica	nizina	blizu	rijetko	nema	1	1
4	2	bjelogorica	brijeg	blizu	rijetko	nema	1	1
4	3	bjelogorica	nizina	daleko	rijetko	nema	1	1
4	4	bjelogorica	brijeg	daleko	rijetko	nema	1	1
4	5	bjelogorica	nizina	blizu	cesto	nema	2	3
4	6	bjelogorica	nizina	blizu	vrlo	nema	4	3
4	7	bjelogorica	nizina	blizu	rijetko	ima	3	3
4	8	bjelogorica	nizina	blizu	cesto	ima	4	5
4	9	bjelogorica	nizina	blizu	vrlo	ima	5	5
4	10	crnogorica	nizina	blizu	rijetko	nema	1	1
4	11	crnogorica	brijeg	blizu	rijetko	nema	1	1
4	12	crnogorica	nizina	daleko	rijetko	nema	1	1
4	13	crnogorica	brijeg	daleko	rijetko	nema	1	1
4	14	crnogorica	nizina	blizu	cesto	nema	3	3
4	15	crnogorica	nizina	blizu	vrlo	nema	4	3
4	16	crnogorica	nizina	blizu	rijetko	ima	2	2
4	17	crnogorica	brijeg	daleko	cesto	ima	4	4
4	18	crnogorica	nizina	blizu	vrlo	ima	4	4

Korištenje sustavnog pristupa i «rad po redu» je omogućio Ivi valjano variranje čimbenika i donošenje valjanih zaključaka o učinku pojedinih čimbenika, čime se približila gotovo 100% uspješnosti. Tek se iznimno dogodilo da je iz eksperimenta u eksperiment promijenila dva čimbenika umjesto jednog, vjerojatno više zbog trenutne nepažnje, nego iz nerazumijevanja potrebe njihovog odvojenog ispitivanja.

Pri ispitivanju učinaka pojedinih čimbenika na drugoj vrsti šuma (crnogorici), Iva je replicirala učinke dobivene na bjelogoričnoj šumi, ali i donijela valjane interakcijske zaključke o učinku vrste šume i drugih čimbenika, prije svega kiselih kiša i nametnika.

Ponovno se pojavila tendencija, pokazana već u prethodnim mjerenjima, da Iva ponavlja ispitivanja nekih čimbenika na različitim razinama drugih varijabli. Primjerice, u trećem mjerenju provjeravala je nepostojanje učinka blizine naselja ne samo u kombinaciji koja uključuje rijetke kisele kiše, nego i u kombinaciji koja uključuje česte kisele kiše. Ona taj postupak opravdava ovako: *«Sad ću samo udaljiti od sela da vidim. Možda na tu šumu (crnogoricu) to utječe, a na bjelogoričnu ne utječe, kad ima srednje kiselih kiša»*. U četvrtom mjerenju, pak, nepostojanje učinka konfiguracije tla provjerava uz obje kategorije čimbenika 'udaljenost šume od naselja'.

Zanimljivo je napomenuti da Iva u trećem mjerenju ne uspijeva uočiti nelinearni učinak kiselih kiša, iako više puta stvara nalaze koji joj omogućuju donošenje valjanih zaključaka o nepostojanju razlika u uništenju šuma između razina 'često' i 'vrlo često padanje kiselih kiša'. To je vjerojatno posljedica toga što je u tim eksperimentima Iva bila okupirana objašnjavanjem učinaka drugih čimbenika (a ne kiselih kiša), ali se može povezati i s njezinom nemogućnošću zamišljanja teorije, odnosno mehanizama koji bi takve nalaze objasnili. To potvrđuju rezultati četvrtog mjerenja, kad Iva, koristeći iste nalaze, zapaža da *«kisele kiše utječu jednako, neovisno o tome padaju li srednje ili često»*, ali dodaje *«malo mi je to čudno, ali dobro....smatram da kad ima više kiselih kiša, normalno je da više uništavaju okoliš...»*. Kao posljedica teškog prihvatanja donesenog zaključka, on se ne pojavljuje u razgovoru o teorijama, kad Iva tvrdi: *«Što je manje kiselih kiša to bolje jer manje uništavaju...Ako padaju rijetko manje je zagađenje tog područja i manje je uništavanje okoliša, a ako padaju češće, toga je više»*. Zbog tog nepriznavanja nelinearnog učinka kiselih kiša, Iva završava rad na zadatku bez ostvarenog maksimalnog broja bodova u stečenom znanju o odnosima između varijabli.

Važno je također napomenuti da stečeno znanje o modelu zadatka i visoka razina strateške izvedbe koju je Iva pokazala tijekom istraživanja nisu bili praćeni postizanjem potpunog metakognitivnog razumijevanja zahtjeva zadatka. Po tome se Iva značajno razlikuje od Borne. Naime, od prve do druge primjene upitnika metakognitivnog znanja kod Ive dolazi do određene promjene u elementu metakognitivnog razumijevanja cilja zadatka, budući da njezin odgovor *«Na ovom zadatku cilj učenika je otkriti što utječe na uništavanje šuma, tj. što više utječe»* sugerira pomak na razinu koja predstavlja shvaćanje zadatka kao onog kojim se želi utvrditi što utječe na rezultate eksperimenata, ali bez isticanja potrebe utvrđivanja učinka svakog pojedinih čimbenika. Izrečeno metastateško razumijevanje se, međutim, zadržava na iznenađujuće niskoj razini, jednako kao i prije početka rada na

zadatku. Na pitanje o potrebnoj strategiji rada za uspješno rješavanje zadatka, Iva odgovara: «*Odabire sličice po želji. Dok odabire sličice, ujedno razmišlja o tome kakvo će rješenje dobiti*». Ovaj je odgovor u nesuglasju s uvidima stečenima tijekom Ivinog rada na zadatku, kad se u njezinim izjavama npr. «*Udaljavam od naselja, a ostalo ostaje isto*» moglo vidjeti da Iva uočava potrebu korištenja strategije kontrole varijabli za zaključivanje o učincima pojedinih čimbenika. Moguće je, međutim, da Iva nije apstrahirala taj princip kontroliranog variranja varijabli kao opće pravilo koje treba uvijek primijeniti u situaciji rada na zadatku o uništenju šuma, odnosno koje treba primijeniti u različitim zadacima istraživačkog učenja.

Konačno, na kraju ovog pregleda Borninog i Ivinog rada na zadatku istraživačkog učenja, moguće je konstatirati postojanje prilično različitih individualnih putova i krivulja razvoja istraživačkih vještina, usprkos sličnim krajnjim rezultatima učenja (prema kriterijima valjanosti zaključivanja i stečenom znanju o odnosima među varijablama). Dok je Iva tijekom cijelog istraživačkog razdoblja pokazivala postepeno napredovanje u strateškoj izvedbi, koje je bilo praćeno (ili možda uvjetovano) porastom planiranja i sustavnosti provedbe eksperimenata, Bornino je djelovanje bilo od početka na višoj razini, pa je svoj vrhunac postiglo već u drugom mjerenju. Uz prednosti koje je ostvario na strateškoj razini, Borna je iskazao i više metastrateško razumijevanje, pa je ono tijekom rada na zadatku postalo potpuno eksplicitno i jasno. Uzimajući u obzir Bornine visoke kognitivne sposobnosti, razvijene istraživačke vještine i metastrateško razumijevanje, nameće se pitanje: Zašto Borna do kraja istraživanja nije konzistentno (u 100% slučajeva) upotrebljavao valjane strategije eksperimentiranja i zaključivanja? Iako slučaj jednog učenika ne može dati potpun i konačan odgovor na ovo pitanje, jedan dio odgovora vjerojatno se može potražiti u njegovom doživljaju zadatka i niskoj vrijednosti koju je postizanje uspjeha na zadatku imalo za njega osobno. Teško je očekivati potpunu usredotočenost i ulaganje maksimalnog napora kojeg istraživački zadatak zahtijeva, ukoliko ne postoji i potpuna motivacijska spremnost na takvo djelovanje.

## **5.9. Zaključna razmatranja o rezultatima kvalitativne analize procesa istraživačkog učenja**

Kvalitativna analiza procesa istraživačkog učenja kod šest učenika različite motivacijske orijentacije za rad na zadatku i različite razine strateške izvedbe omogućila je ilustraciju sličnosti i razlika u istraživačkim pristupima između motiviranijih i manje motiviranih učenika, kao i između uspješnijih i manje uspješnih učenika, te je poslužila za dublje ispitivanje uvjeta koji dovode do promjena u korištenim strategijama eksperimentiranja i zaključivanja, te za propitivanje međudnosa motivacijskih, metakognitivnih i kognitivnih procesa istraživačkog učenja. Umjesto opisivanja procesa istraživačkog učenja nekog prosječnog ili tipičnog učenika, namjera je kvalitativne analize bila, korištenjem «informativski bogatih» slučajeva, osigurati uvide o ulozi motivacijskih i metakognitivnih čimbenika u procesima i ishodima istraživačkog učenja, koji nisu mogli biti postignuti kroz kvantitativne analize podataka. Posebna pozornost bila je usmjerena na analizu promjena u korištenju strategija eksperimentiranja i zaključivanja, kao i na razumijevanje čimbenika koji ograničavaju ili facilitiraju te promjene.

Analiza istraživačkog učenja kroz četiri mjerenja otkriva postojanje prilično različitih putova razvoja istraživačkih vještina između pojedinih učenika, a ukazuje i na značajne intraindividualne varijacije u eksperimentiranju i zaključivanju tijekom cijelog istraživačkog razdoblja. Tim se nalazom potvrđuju nalazi drugih mikrorazvojnih istraživanja koja također naglašavaju varijabilitet u strateškom djelovanju kao temeljnu karakteristiku učeničkog rada na zadacima istraživačkog učenja (Kuhn, 2001b, 2002a, 2002b). Intraindividualni varijabilitet se očituje u tome da učenici unutar istih mjerenja, u susjednim eksperimentima, paralelno koriste različite istraživačke pristupe, od kojih su neki valjani i učinkoviti, a neki nevaljani ili neučinkoviti. Događa se da čak i u istom eksperimentu učenik donese valjani zaključak o učinku jednog čimbenika (na temelju usporedbe rezultata tog eksperimenta s prijašnjim eksperimentom, koji se međusobno razlikuju samo po razini jedne varijable), ali i nevaljani zaključak o učinku drugog čimbenika, na temelju zajedničkog pojavljivanja tog čimbenika i određenog eksperimentalnog rezultata.

Analiza šest slučajeva također pokazuje da je sudjelovanje učenika u situacijama koje od njih zahtijevaju samostalno eksperimentiranje i kauzalno zaključivanje bilo dovoljan poticaj za generiranje novih, valjanijih istraživačkih strategija. Pokazuje se da su svi

učenici sposobni izvesti barem poneku valjanu usporedbu i donijeti valjani zaključak o učinku nekog čimbenika, no često se vraćaju na nevaljano eksperimentiranje i zaključivanje. Kao i druga mikrorazvojna istraživanja u području istraživačkog učenja (Kuhn i sur., 1992, 1995; Schauble, 1996), ovo istraživanje potvrđuje da učenici ne pokazuju nagli i nepovratni prijelaz s nevaljanog na valjano eksperimentiranje i zaključivanje, već se i valjane i nevaljane strategije pojavljuju kroz sva četiri mjerenja. Valjane strategije se postupno ugrađuju u repertoar istraživačkog ponašanja, a nevaljane strategije polako slabe i nestaju. Čak i uspješni učenici, oni koji postižu visoku razinu strateške izvedbe već na početku rada na zadatku, ne uspijevaju konzistentno koristiti valjane strategije kroz sve eksperimente koje provode. Ovi nalazi sugeriraju da najveći izazov za učenike pri radu na zadatku istraživačkog učenja vjerojatno ne predstavlja svladavanje izvođenja novih, valjanih strategija, nego ukidanje onih starih i nevaljanih.

Napredak u valjanosti zaključivanja koji učenici pokazuju zasniva se na sve uspješnijoj koordinaciji prikupljenih nalaza i teorija koje učenici imaju o učincima pojedinih čimbenika na uništenje šuma. Dok se u početnim mjerenjima, kod manje uspješnih učenika, pojavljuje mnogo zaključaka za koje su objašnjenja teorijski zasnovana, a ne utemeljena na podacima, u kasnijim mjerenjima čak i ti učenici konzistentno uključuju podatke u svoje zaključke i pokazuju poboljšano razlikovanje vlastitih teorija od nalaza, kao i mogućnost (barem privremene) promjene vlastitih netočnih teorija. Međutim, ti učenici tijekom cijelog istraživanja imaju problema s nalazima koji se ne slažu s njihovim kauzalnim teorijama, pa donose nevaljane inkluzivne zaključke na temelju nekontroliranih usporedbi dvaju ili više eksperimenata, ili na temelju generaliziranih usporedbi kroz cijeli skup prikupljenih podataka. U pokušaju pomirenja vlastitih teorija i nesukladnih nalaza, učenici koriste različite metode kako bi zaštitili vlastite teorije, na primjer selektivno izabiru i koriste podatke kao ilustraciju svojih prethodnih teorija, ignoriraju neke kovarijacije (ili nepostojanje kovarijacije), iskrivljuju nalaze kako bi odgovarali njihovim teorijama, okreću se drugim čimbenicima kao mogućim objašnjenjima neočekivanih kovarijacija, uparuju čimbenike tako da osiguraju kovariranje s ishodima, ograničavaju zaključak ili teoriju o učinku nekog čimbenika samo na neke situacije ili primjere, ne provjeravaju neke čimbenike itd. Znakovit je podatak o čak tri analizirana slučajeve (Leni, Oliveru i Marinu<sup>68</sup>) koji istraživanje završavaju s netočnom kauzalnom teorijom o

---

<sup>68</sup> Lena: negativnija motivacijska orijentacija - nema značajnog napretka u strateškoj izvedbi, Oliver – pozitivnija motivacijska orijentacija – nema značajnog napretka u strateškoj izvedbi, Marin: negativnija

čimbeniku 'udaljenost šuma od naselja', te o Dei koja postavlja točnu teoriju o ovom čimbeniku, ali je ograničava na slučajeve niske uništenosti šuma.

Analiza obrazaca promjena u korištenim strategijama eksperimentiranja i zaključivanja, kao i analiza uvjeta pod kojima dolazi (ili ne dolazi) do jačanja valjanosti zaključivanja ukazuje na moguću ključnu ulogu metakognicije u tim promjenama, odnosno na nužnost postojanja određenog metakognitivnog razumijevanja zahtjeva zadatka i korištenja metakognitivnih vještina koje se odnose na planiranje i organiziranje, te kontinuirano praćenje i reguliranje istraživačkih aktivnosti.

Pokazuje se da u početnom metakognitivnom znanju o cilju zadatka i strategijama rada na zadatku nema značajnijih razlika među učenicima koji postižu različitu razinu strateškog uspjeha na zadatku, što potvrđuje da se metakognitivno razumijevanje može potaknuti tek angažmanom na zadatku, a ne samo upoznavanjem učenika sa sadržajem zadatka i procedurama rada na njemu.

Na početku rada na zadatku niti jedan učenik uključen u studiju slučajeva pod ciljem zadatka ne podrazumijeva analizu učinaka pojedinih čimbenika, već se uglavnom zadržava na razini koja označava težnju za postizanjem pozitivnih rezultata. Početno metastrateško razumijevanje je kod svih tih učenika na nultoj razini, što znači da kod njih nema svijesti o potrebi korištenja određenih strategija za uspješno rješavanje istraživačkog zadatka. Budući da meta razina upravlja odabirom strategija prema učenikovom razumijevanju toga hoće li izabrani pristup dovesti do onoga što je shvaćeno kao cilj zadatka, na početku rada na zadatku o uništenju šuma učenici slijede svoje metakognitivno razumijevanje i biraju (u najboljem slučaju) kombinacije čimbenika s ciljem generiranja određenih ishoda eksperimenata. U nastavku rada na zadatku učenici počinju koristiti različite pristupe, pa se na strateškoj razini već u prvom mjerenju pojavljuju velike razlike između učenika. Kod nekih učenika događa se da povratne informacije o primjeni istraživačkih strategija nastale kao posljedica provedbe prvih eksperimenata brzo mijenjaju meta razinu, dok kod drugih to nije tako, pa se niska razina metakognitivnog razumijevanja zadržava i nastavlja ograničavati strateško djelovanje kroz duže vrijeme. Primjer brzog jačanja meta razine je Borna<sup>69</sup>, kojeg odlikuju visoke sposobnosti induktivnog rezoniranja, a kojem je već jedno pojašnjenje o tome što će biti pitan na kraju svakog mjerenja bilo dovoljno da se od biranja

---

motivacija – napredovanje u strateškoj izvedbi, Dea: pozitivnija motivacijska orijentacija – napredovanje u strateškoj izvedbi

<sup>69</sup> Borna: negativnija motivacijska orijentacija – visoka strateška izvedba od početka rada na zadatku



kombinacije čimbenika koja daje minimalno uništenje šuma potpuno preusmjeri već u trećem eksperimentu na ispitivanje učinaka pojedinih čimbenika, intencionalno korištenje strategije kontrole varijabli i valjano zaključivanje. Slično se dogodilo i Ivi<sup>70</sup>, koja je također rano uočila nemogućnost donošenja zaključaka na temelju nekontroliranih usporedbi, ali kod nje prijelaz na potpuno valjano eksperimentiranje i zaključivanje nije bio toliko brz i izrazit.

Kod drugih učenika (Dee i Marina, ali zapravo i kod Ive koja u odnosu na njih kreće s više početne razine), tijekom rada na zadatku istraživačkog učenja dolazi do postepenog i paralelnog jačanja strateškog djelovanja i metakognitivnog razumijevanja zahtjeva zadatka (jačanja svijesti o postojanju valjanih strategija i razumijevanja korisnosti njihovog korištenja). Veliku važnost u jačanju valjanosti eksperimentiranja i zaključivanja zasigurno ima jačanje korištenja metakognitivnih vještina, odnosno zauzimanje sve sustavnijeg pristupa eksperimentiranju i poboljšano planiranje i organiziranje učenja u kasnijim fazama rada na zadatku. Iz sustavnog pristupa eksperimentiranju proizlazi orijentacija na ispitivanje jednog po jednog čimbenika, koja omogućuje stvaranje nalaza koji omogućuju valjanu usporedbu i pruža osnovu za analiziranje i interpretaciju učinaka pojedinih čimbenika na valjan način.

Učenici koji su tijekom rada na zadatku pokazali napredovanje u strateškoj izvedbi, u prvim su mjerenjima koristili neučinkovit pristup i provodili eksperimente bez plana, nesustavno i bez namjere analize učinka pojedinih čimbenika. U sljedećim mjerenjima su napredovali preko eksperimentiranja s ciljem generiranja određenih ishoda do analize učinaka pojedinih čimbenika, pritom koristeći sustavniji, analitičniji i refleksivniji pristup. Prve valjane zaključke ovi su učenici donijeli neplanskim i nenamjernim valjanim variranjem varijabli između eksperimenata, u kontekstu provedbe eksperimenata s ciljem generiranja određenih ishoda ili nakon dobivanja nekih neobičnih i neočekivanih rezultata. Iako su ti prvi valjani zaključci utemeljeni na eksperimentima koji su postavljeni na valjan način bez takve namjere i plana, to ne znači da su doneseni bez korištenja složenih kognitivnih vještina koje uključuju analiziranje prikupljenih nalaza, prepoznavanje važnosti tih nalaza za zaključivanje, uspoređivanje eksperimenata i prikladno objašnjavanje uočenih razlika (ili nepostojanje razlika) u rezultatima. Stoga donošenje tih zaključaka, ipak, ukazuje na korištenje analitičkog i dubljeg procesiranja prikupljenih podataka.

---

<sup>70</sup> Iva: pozitivnija motivacijska orijentacija - visoka strateška izvedba od početka rada na zadatku

S provođenjem prvih valjanih usporedbi i donošenjem prvih valjanih zaključaka, učenici postepeno počinju shvaćati vrijednost i upotrebljivost pristupa ispitivanja učinaka pojedinih čimbenika u odnosu na pristup eksperimentiranja s ciljem generiranja određenih ishoda, čime postaju svjesniji «pravog» cilja zadatka. Postepeno počinju uočavati i prednosti koje donosi korištenje valjanih strategija eksperimentiranja za razumijevanje odnosa među varijablama (iako se na to uglavnom ne osvrću u svojim izjavama). Osim toga što korištenje valjanih istraživačkih strategija jača usmjerenost na analizu pojedinih čimbenika na meta razini i povećava svijest o potrebi variranja jednog čimbenika u jednom trenutku, događa se i drugačiji proces. Korištenje nevaljanih strategija potiče razumijevanje neprikladnosti i neupotrebljivosti tih postupaka i vodi prepoznavanju potrebe za pronalaženjem drugih pristupa i metastrateškoj potrazi za novim strategijama. Učenici postaju svjesni neučinkovitosti korištenih strategija za otkrivanje učinaka čimbenika i za odgovaranje na pitanja istraživačice «Što si zaključio o utjecaju čimbenika na uništenje šuma?»), što ih čini sklonima traženju novih pristupa. O tome da poticaj za mijenjanje strategija može doći iz opažanja problema u provođenju eksperimenata i određenog razumijevanja smanjene mogućnosti zaključivanja na temelju nekontroliranih eksperimenata izvedenih s ciljem generiranja određenih eksperimentalnih ishoda, jasno govori sljedeća izjava koju daje Dea, učenica koja je do kraja istraživanja napredovala do 100% valjanih zaključaka: «...ali nekako mi se čini kako sam prošli put radila.....da nisam baš shvatila koliko neke stvari imaju utjecaja.....» i «Sad pokušavam otkriti koliko svaki od tih čimbenika ima zapravo veze....Sad ispitujem kisele kiše. Sve sam čimbenike stavila na najmanje, a kisele kiše na najviše».

Ovi nalazi potvrđuju da veće metakognitivno razumijevanje zahtjeva zadatka može slijediti i nakon primjene valjanih i nevaljanih strategija eksperimentiranja, te pokazuju da povećana svjesnost na meta razini vodi odabiru i primjeni boljih strategija. O istim međuodnosima strateškog i metastrateškog djelovanja izvještava već Kuhn i Pearsall (1998).

Učenici (Dea, Marin, Iva) koji pokazuju izrazit napredak u strateškom djelovanju na zadatku istraživačkog učenja, u zadnjim mjerenjima prilaze rješavanju zadatka planirajući slijed eksperimenata i više-manje pridržavajući se planirane organizacije eksperimenata. Imaju u vidu cjelokupnu strukturu zadatka, rade po redu, ispituju učinak pojedinih čimbenika te namjerno koriste valjano variranje čimbenika između pojedinih eksperimenata. Ti su učenici, dakle, napredovali od stvaranja neinterpretabilnih

eksperimenata i spremnog donošenja nevaljanih zaključaka, preko neplaniranog i slučajnog izvođenja valjanog variranja čimbenika i rastućeg razumijevanja nemogućnosti interpretiranja nekontroliranih nalaza i vrste nalaza koji su potrebni za donošenje valjanih zaključaka, do svjesnog i namjernog variranja jednog čimbenika po eksperimentu. Pri usporedbama, ovi učenici obično smatraju referentnim eksperimentom onaj koji dovodi do najmanjeg uništenja šuma, pa u ispitivanje učinka pojedinih čimbenika kreću mijenjanjem pojedinog čimbenika u odnosu na tu kombinaciju koja dovodi do najmanjeg uništenja.

Važno je, međutim, istaknuti mogućnost da učenici koji pokazuju izrazit napredak u valjanosti zaključivanja pokazuju porast metakognitivnog znanja o cilju zadatka, ali eksplicitno metastrateško znanje ostaje na niskoj razini. Stoga se može reći da je njihovo strateško djelovanje na kraju istraživanja čak naprednije od razumijevanja strategija kojeg iskazuju na meta razini, kao i to da je vjerojatno potrebno određeno vrijeme za konsolidaciju postignuća na strateškoj razini, kako bi se ono očitovalo u metastrateškom znanju.

Za napredovanje u strateškoj izvedbi i ostvarivanje strateškog uspjeha čini se dovoljnom već analitička usmjerenost na čimbenike (nasuprot usmjerenosti na ishode eksperimenata) koju osigurava metakognitivno znanje o cilju zadatka, čak i kad se ono zadržava na najosnovnijem obliku «Što utječe na uništenje šuma?» (kao što je to prisutno kod Marina i Ive). Visoka razina strateške izvedbe može se, dakle, pojaviti bez eksplicitnog metastrateškog razumijevanja - bez jasne svijesti o postojanju različitih strategija i bez mogućnosti refleksije o strategijama potrebnima za ostvarivanje cilja zadatka. Iako učenici pri eksperimentiranju u zadnjim mjerenjima govore, primjerice, «*sad ću sve isto, samo ću staviti blizu naselja*», što upućuje na postojanje implicitnog razumijevanja o strategiji kontrole varijable kao strategiji koja je primjenjiva na zadatku kojim se istražuje što utječe na uništenje šuma, pitanje je koliko učenici zaista razumiju nužnost korištenja kontrole strategije varijabli i nužnost provođenja usporedbi koje omogućuju valjano zaključivanje i odgovaranje na cilj zadatka, koliko razumiju zašto neki drugi pristupi nisu valjani, te koliko su ta znanja generalizirali kao opća pravila koja se mogu primijeniti u drugim situacijama istraživačkog učenja.

Važnost metakognitivnih procesa u određivanju tijeka i rezultata istraživačkog učenja ne pokazuje se samo kod učenika koji izrazito napreduju u strateškoj izvedbi na zadatku istraživačkog učenja, nego i kod učenika koji ne postižu takav uspjeh. Postoje učenici (Lena i Oliver) koji do kraja istraživanja ne postižu značajan napredak niti u području

strateške izvedbe, niti u području metakognitivnog razumijevanja cilja i strategija rada na zadatku. Iako se pokazuje da su ti učenici također sposobni, barem u nekim slučajevima, izvesti valjane strategije eksperimentiranja i zaključivanja, takvo eksperimentiranje i zaključivanje ne dobiva zamah u njihovom radu.

Analiza procesa učenja kod ovih učenika pokazuje da se njihov istraživački pristup ne razlikuje značajno od pristupa koji u prvim mjerenjima zauzimaju učenici koji kasnije pokazuju značajan napredak prema višoj razini strateške izvedbe. No, za ove je učenike karakteristično korištenje neplanskog, nesustavnog, neanalitičkog i nerefleksivnog pristupa u eksperimentiranju i zaključivanju tijekom cijelog istraživačkog razdoblja, kao i zadržavanje metakognitivnog razumijevanja zahtjeva zadatka na niskoj razini.

Do kraja rada na zadatku ovi učenici ostaju orijentirani na ishode eksperimenata (a ne na analizu čimbenika koji dovode do ishoda), pa ciljem zadatka vide demonstriranje pojedinih stupnjeva šume, odnosno postizanje pozitivnog ishoda minimalnog uništenja. Osim slabog razumijevanja cilja zadatka, ovi učenici pokazuju i nepostojanje refleksije o pristupima koji bi omogućili donošenje valjanih zaključaka, tako da već oskudne nalaze koji su doneseni na nekontrolirani način smatraju prikladnima za donošenje zaključaka.

Tijekom svih četiri mjerenja ovi učenici podcjenjuju težinu zadatka, kao i vlastitu kompetentnost za njegovo rješavanje, pa ni ne razumiju da rješenje zadatka koje nude nije točno. Do kraja istraživanja ne dovode u pitanje svoj istraživački pristup niti ga značajno mijenjaju. Kao posljedica toga, ne uspijevaju spoznati da njihova reprezentacija cilja zadatka nije prikladna, kao ni da pristupi koje koriste u eksperimentiranju nisu valjani i učinkoviti za otkrivanje odnosa među varijablama.

Većina zaključaka ovih ispitanika je nevaljana, i donesena brzim i neanalitičkim pristupom, bez namjerne konstrukcije eksperimenata, bez metakognitivnog praćenja tijekom eksperimentiranja i bez dubljeg, promišljenijeg procesiranja prikupljenih nalaza. Mnogo je zaključaka doneseno na temelju usporedbe eksperimenata koji međusobno ne stoje u nekom jasnom odnosu (varirano je odjednom više čimbenika), ali pojavljuju se i znatan broj teorijski utemeljenih zaključaka, u kojima učenici uopće ne uzimaju u obzir nalaze provedenih eksperimenata, već svoj odgovor osnivaju na znanjima i očekivanjima koja otprije imaju o predmetu ispitivanja. Također, određeni broj zaključaka se temelji na opažanju rezultata samo jednog eksperimenta i na objašnjenjima koja kao dokaz postojanja

kauzalnog učinka određenog čimbenika uzimaju u obzir zajedničko pojavljivanje tog čimbenika i pojedinog eksperimentalnog ishoda.

Analiza istraživačkog učenja neuspješnih učenika, dakle, pokazuje da je održavanje strateške izvedbe na niskoj razini praćeno neprikladnim funkcioniranjem na meta razini. Može se pretpostaviti da je upravo neprikladno metakognitivno razumijevanje zahtjeva zadatka, nedostatna svijest o potrebi sustavnog i planiranog eksperimentiranja, kao i nedovoljno metakognitivno praćenje i reguliranje rada na zadatku ograničilo strateško napredovanje i stjecanje znanja o odnosima između varijabli kod ovih učenika. Kao što navode Kuhn i Pearsall (1998), moguće je da je meta razina kod ovih učenika suviše slaba da bi mogla iskoristiti povratne informacije koje dolaze s razine izvedbe, te kontrolirati i upravljati izvedbom strategija na učinkovitiji i primjereniji način.

Usporedba procesa istraživačkog učenja Olivera i Lene ukazuje, međutim, na ponešto drugačije izvore neplanskog, nesustavnog i neanalitičkog pristupa eksperimentiranju kod ovih učenika, koji sve do kraja istraživanja ne pokazuju značajniji napredak u strateškom djelovanju. Kod Olivera, koji inače pripada klasteru pozitivne motivacijske orijentacije za rad na zadatku, neučinkovit i nepromišljen istraživački pristup se može povezati prvenstveno s njegovim metakognitivnim deficitima, prije svega s njegovom nemogućnošću da kontinuirano prati i regulira svoj rad na zadatku, kontrolira svoju spontanu brzopletost, koordinira provedbu eksperimenata (njihov slijed i usklađenost namjere i zaključaka unutar pojedinog eksperimenta) i ograniči svoje teorijski motivirano zaključivanje.

Lenin slučaj, pak, pokazuje da niska razina postignuća na zadatku istraživačkog učenja može biti uvjetovana ne samo netočnim razumijevanjem stvarnih zahtjeva zadatka i nedovoljnim korištenjem metakognitivnih vještina planiranja, organiziranja i praćenja istraživačke aktivnosti, već i motivacijskim razlozima – niskom početnom motivacijom, te padom motivacije tijekom rada na zadatku. Opažanje njezinog rada na zadatku je pokazalo da je negativna motivacijska orijentacija mogla pogodovati zauzimanju nepromišljenog i površnog pristupa eksperimentiranju i zaključivanju, te nekorištenju metakognitivnih vještina potrebnih za uspješan rad na zadatku. Usprkos visokim sposobnostima induktivnog rezoniranja, Lena tako završava istraživanje s izrazito niskim učinkom na zadatku.

Primjer Marina iz početne faze rada na zadatku također sugerira da niska motivacija može negativno djelovati na procese istraživačkog učenja i onemogućiti prihvaćanje sustavnijeg istraživačkog pristupa i dubljeg procesiranja stvorenih nalaza. Njegov je slučaj zanimljiv i zato što upućuje na mogućnost da se (blage) promjene u motivaciji odvijaju paralelno s promjenama u istraživačkim pristupima. Iako je nemoguće utvrditi što je uzrok, a što posljedica ovih promjena, moguće je zamisliti da poboljšanje motivacije uvjetuje promjene u pristupu radu i zauzimanje organiziranijeg i refleksivnijeg pristupa, kao i da promjene u istraživačkom pristupu i uspjeh koji iz toga proizlazi potiče promjene u motivaciji.

Kvalitativna analiza istraživačkog učenja stoga ukazuje na moguću ulogu motivacije u procesima i ishodima istraživačkog učenja. Time se potvrđuju nalazi istraživanja Rheinberga i Vollmeyerice koji kažu da u zadacima istraživačkog učenja, u kojima učenici imaju slobodu izbora istraživačkih pristupa i sami određuju tijek i trajanje učenja, motivacija može utjecati na način na koji se pristupa učenju (npr. Rheinberg i sur., 2000, 2005). S jedne strane, pozitivna motivacija može stvoriti povoljan okvir za primjenu (kognitivno zahtjevnijih) strategija koje vode valjanim zaključcima, jer može usmjeriti učenike na planiranje i sustavno organiziranje procesa eksperimentiranja, namjernu konstrukciju eksperimenata na određeni način, temeljitije ispitivanje prostora eksperimenta, održavanje pažnje i ulaganje kognitivnog napora za analitično i refleksivno interpretiranje nalaza eksperimenata. Učenici koji kreću u rad na zadatku s pozitivnim očekivanjima uobičajeno i zadržavaju takva očekivanja tijekom rada, što dalje pogoduje korištenju sustavnog pristupa eksperimentiranju, usprkos kognitivnoj zahtjevnosti i potrebi dubljeg procesiranja koje takav pristup zahtijeva. S druge strane, manjak motivacije može voditi negativnim ishodima i uvjetovati da učenik ne koristi vještine koje posjeduje i koje je stekao tijekom učenja, ili da ne koristi mogućnosti koje mu pruža situacija učenja. Analiza procesa istraživačkog učenja kod tri učenika negativnije motivacijske orijentacije pokazuje da manifestacije motivacijskih utjecaja mogu biti prilično različite. S jedne strane, manjak motivacije za rad na zadatku može voditi odabiru neplanskog i nesustavnog pristupa eksperimentiranju, kao i odabiru nepromišljenog i neanalitičkog pristupa zaključivanja, te pogodovati nekorištenju metakognitivnih vještina praćenja i kontrole istraživačkih aktivnosti. Mnoštvo eksperimenata može biti izvedeno brzo i nepromišljeno (čak i nasumce), i rezultirati mnoštvom nevaljanih zaključaka (Lena). Utjecaj manjka motivacije može biti očitovan i u preranom prekidanju učenja i provedbi malog broja eksperimenata, što značajno ograničava nalaze koje učenik stvara i onemogućuje

sagledavanje svih odnosa među varijablama (Marin). U slučaju postojanja visokih strateških i metastrateških kompetencija (Borna), manjak motivacije može biti čimbenik koji vodi prebrzoj provedbi eksperimenata i nekonzistentnoj primjeni valjanih strategija eksperimentiranja i zaključivanja, u situaciji kad zadatak prestaje biti nov i izazovan.

Različite manifestacije motivacijskih utjecaja zasigurno su utjecale na neutvrđivanje statistički značajnih razlika u pojedinim pokazateljima procesa i ishoda istraživačkog učenja između učenika koji pripadaju različitim motivacijskim profilima. Kvalitativna analiza procesa učenja i obrazaca promjena u korištenim strategijama eksperimentiranja i zaključivanja, međutim, sugerira da motivacija može usmjeriti, pospješiti ili ograničiti istraživačko učenje djelovanjem na odabir istraživačkog pristupa i na razinu usredotočenosti, posvećenosti i ustrajnosti koju učenik pokazuje pri odabiru eksperimenata i analizi nalaza. Ipak, motivacija se može smatrati nužnim, ali ne i dovoljnim uvjetom za postizanje uspjeha na zadatku istraživačkog učenja. Osim općih kognitivnih sposobnosti i sposobnosti izvedbe istraživačkih strategija i vještina, za napredovanje na zadatku istraživačkog učenja i ostvarenje visoke razine strateške izvedbe ključnom se pokazuje razvijenost metakognicije. Bez metakognicije, nema uspješnog rješavanja zadatka istraživačkog učenja, čak i uz visoku motivaciju (kao što nam pokazuje slučaj Olivera). Visoke rezultate na zadatku istraživačkog učenja je moguće ostvariti čak i bez visoke motivacije (kao što je vidljivo iz Borninog primjera), ali je u takvim uvjetima teško očekivati konzistentnu primjenu valjanih metoda eksperimentiranja i zaključivanja u situacijama ponavljano rada na istom zadatku. Borna koji brzo postiže visoku razinu strateške izvedbe ima poteškoća u održavanju motivacije za nastavljanje rada na zadatku, pa u kasnijim fazama rada pokazuju i blago nazadovanje u korištenim pristupima eksperimentiranju i zaključivanju. Da bi se postigla konzistentna uporaba valjanih strategija eksperimentiranja i zaključivanja, nije dovoljno imati samo visoke sposobnosti primjene tih vještina, prikladno metakognitivno znanje o zahtjevima zadatka i strategijama potrebnima za njegovo rješavanje, kao i metakognitivne vještine odabira, praćenja i regulacije korištenja tih strategija u pojedinim situacijama učenja. Potrebno je samoregulirati vlastitu motivaciju i emocije i održati visoku razinu usredotočenosti, analitičnosti, kao i spremnost investiranja truda u situaciji gubitka interesa za zadatak i doživljaja zadatka kao neizazovnog.

Dosad izneseni rezultati kvalitativne analize upućuju na važnost motivacije i metakognicije u procesima i ishodima istraživačkog učenja, te na probleme u strateškom djelovanju koji se mogu povezati s manjkom metakognitivnih znanja i vještina, te manjkom motivacije.

Na kraju, potrebno je istaknuti da analiza strateškog djelovanja učenika ukazuje i na određene strateške deficite učenika, prije svega na probleme izvođenja valjanih interakcijskih zaključaka. Pokazuje se da svi analizirani slučajevi postavljaju složene teorije o učincima čimbenika i donose, barem povremeno, zaključke koji upućuju na postojanje interakcijskih veza između pojedinih čimbenika. Pritom, u interakcijske se odnose uvijek uključuje čimbenik 'vrsta drveća u šumi' i neki drugi čimbenik, vjerojatno zato što su to učinci za koje učenici lako mogu razviti određene teorijske konceptualizacije (objašnjenja) interakcijskog djelovanja.

Učenici koje obilježava niska razina strateške izvedbe ne uspijevaju donijeti interakcijske zaključke drugačije nego teorijske. Niska razvijenost njihovih metastrateških, ali i strateških vještina ne omogućuje im stvaranje nalaza kojima bi na valjan način ispitali svoje složene teorije o interakcijskim učincima određenih čimbenika.

Uspješniji učenici, oni koji do kraja istraživanja napreduju prema razini strateškog uspjeha i oni koji od početka pokazuju većinsko valjano zaključivanje o jednostavnim učincima, uglavnom napreduju i u donošenju valjanih interakcijskih zaključaka. Jedino Marinu ne uspijeva donijeti niti jedan valjani interakcijski zaključak tijekom cijelog istraživanja, dok ostali učenici (Dea, Iva i Borna) ostvaruju gotovo potpuni uspjeh na kraju istraživanja i po ovome kriteriju.

Analiza povremenih nevaljanih interakcijskih zaključaka koje donose ovi ispitanici pokazuje na poteškoće u koordiniranju usporedbi više eksperimenata i zadržavanju analitičke usmjerenosti na utvrđivanje interakcijskih učinaka. Pri stvaranju nalaza za utvrđivanje interakcijskih učinaka, učenici trebaju izraditi minimalno četiri eksperimenata koji se međusobno razlikuju samo u kombinacijama kategorija ispitivanih čimbenika. Pri konstrukciji tih eksperimenata, učenici često izgube fokus, pa niti ne izvedu svih četiri eksperimenata potrebnih za valjani interakcijski zaključak. Ponekad fokus izgube u fazi donošenja zaključka, pa se umjesto na interakcijski zaključak usmjeravaju na neki drugi čimbenik, ili interpretiraju glavni učinak jednog čimbenika u dvije situacije. Ponekad učenici izvedu sva četiri pokusa, ali ne kontroliraju druge čimbenike koji nisu predmet



ispitivanja, pa testiranje interakcijskog učinka završi kao ponavljanje jednostavnog učinka jednog čimbenika u drugoj kombinaciji čimbenika.

Uz (povremene) teškoće u izvođenju valjanih interakcijskih zaključaka, zapaženo je da učenici imaju poteškoća u verbalizaciji interakcijskih učinaka, kao i u opisivanju vlastitih očekivanja vezanih uz ove učinke. Poteškoće te vrste prisutne su i kod opisa i interpretacija jednostavnih učinaka, ali kod složenih učinaka posebno dolaze do izražaja.

Primjeri tipičnih odgovora vezanih uz točne i valjano donesene interakcijske zaključke su sljedeći:

*«Bjelogorične šume su malo osjetljivije na nametnike, dok crnogorične baš i nisu» (Dea)*

*«Mislio sam da kisela kiša ima više utjecaja na ovu vrstu šume, a dobio sam jednako. Znači da...vrste šume i količine kiša djeluju jednako, da to nije povezano».* (Borna)

*«Nema veze kad udaljim od sela crnogoricu, a nije utjecalo niti na onu vrstu šuma» (Iva)*

Iz ovih je citata očito da učenicima nedostaje rječnik kojim bi na (znanstveno) korektan i potpun način opisali opažene nalaze eksperimenata i izrazili postojanje ili nepostojanje interakcijskih učinaka.

## POGLAVLJE 6. ZAKLJUČAK

---

Zaključno poglavlje sastoji se od četiri dijela. U prvom dijelu raspravlja se o nekim metodološkim pitanjima koja proizlaze iz ispitivanja istraživačkog učenja kao procesa i korištenja mikrorazvojne metodologije, kao i o mogućim metodološkim ograničenjima rada. Drugi dio zaključnog poglavlja odgovara na istraživačka pitanja kroz integriranje rezultata analiza skupnih podataka i rezultata kvalitativne analize slučajeva i završnu raspravu o doprinosu istraživanja području istraživanja istraživačkog učenja. Poglavlje završava razmatranjem implikacija koje rezultati istraživanja imaju za buduća istraživanja i za obrazovnu praksu.

### 6.1. Metodološke implikacije i ograničenja istraživanja

Iz metodološke perspektive, ovo je istraživanje obilježilo nekoliko elemenata. Kao prvo, interes za izučavanje promjena i međuodnosa kognitivnih, metakognitivnih i motivacijskih procesa koji se odvijaju kad učenici samostalno eksperimentiraju odredio je usmjerenost na mikrorazinu iskustva rada na jednom zadatku i na određeni broj cjelovitih epizoda učenja koje su praćene u realnom vremenu. Kao drugo, unutar okvira tog zadatka i tih ponavljanih specifičnih situacija učenja, subjektivno iskustvo učenika tijekom rada na zadatku je praćeno direktnim, simultanim i ponavljanim mjerenjima različitih kognitivnih, metakognitivnih, motivacijskih i emocionalnih procesa, u slijedu u kojem su se događali. Svi su procesi bilježeni kao situacijski specifični procesi koji se održavaju, mijenjaju ili razvijaju unutar i između pojedinih situacija učenja. Nije praćeno samo ono što učenici rade kad pokušavaju riješiti zadatak, nego i to što razmišljaju i doživljuju tijekom učenja. Kao treće, pod pretpostavkom da niti jedna pojedinačna metoda prikupljanja podataka ne može u potpunosti prikladno i valjano zahvatiti promjenjive obrasce istraživačkih aktivnosti, misli i doživljaja koji se pojavljuju u situacijama istraživačkog učenja, u istraživanju su korišteni različiti izvori podataka za mjerenje pojedinih procesa. Korišteni su odgovori učenika na pitanja u strukturiranim upitnicima, učeničke verbalizacije prikupljene u «misli naglas» protokolima i polustrukturiranim intervjuima, ali i praćenje tragova aktivnosti učenika u FILE-u putem automatskog računalnog zapisnika i opažanje učeničkih aktivnosti i ponašanja. Kao četvrto, analiza prikupljenih podataka je uključivala i kvantitativne i kvalitativne analitičke postupke jer počiva na ideji o komplementarnosti

ovih pristupa i na uvjerenju o mogućnosti dobivanja cjelovitijih i kvalitetnijih odgovora na istraživačka pitanja u slučaju kombiniranja ovih pristupa, nego u slučaju korištenja samo jedne vrste analize. Kvantitativna analiza je bila usmjerena na analizu skupnih rezultata (grupnih prosjeka), pa je pružila podatke o pojavljivanju i učestalosti korištenja određenih istraživačkih pristupa unutar skupine učenika, kao i podatke o normativnim promjenama u kognitivnim, metakognitivnim i motivacijskim sastavnicama istraživačkog učenja između pojedinih mjerenja i o povezanosti tih procesa i rezultata učenja na razini pojedinih mjerenja. Kvalitativna analiza procesa učenja nekoliko informativnih slučajeva (učenika) je dala živost i ilustrativnu dubinu podacima dobivenim kroz kvantitativne analize, ali je omogućila i dubinsko zahvaćanje procesa učenja unutar pojedinih mjerenja, opisivanje individualnih iskustava, praćenje individualnih obrazaca promjena i uočavanje intra- i interindividualnih razlika u istraživačkim pristupima, što kvantitativna analiza nije mogla osigurati. Detaljnim opažanjem i praćenjem učenika pri izvođenju svakog pojedinog eksperimenta, smještanjem pojedinih aktivnosti učenika u kontekst njegovog cjelokupnog iskustva u radu na zadatku i analiziranjem obrazaca promjena u korištenju istraživačkim pristupima unutar i između pojedinih mjerenja, bilo je omogućeno bolje razumijevanje individualnih obrazaca promjena u procesima istraživačkog učenja i osiguran je cjelovitiji pogled na to kako se istraživačko učenje odvija, kako učenici razvijaju istraživačke vještine i otkrivaju nove strategije, koji su uvjeti pod kojima dolazi do promjena itd.

Svi dosad navedeni elementi metodološkog pristupa provedenog istraživanja smatrani su njegovim jakim stranama. Zbog relativne blizine i intenziteta mjerenja cjelovitih epizoda učenja, te zbog bogatstva prikupljenih kvantitativnih i kvalitativnih podataka, korišteni istraživački pristup je omogućio zahvaćanje procesa promjena u stjecanju znanja i razvijanju istraživačkih vještina i strategija, te istraživanje toga kako u specifičnim situacijama učenja međusobno djeluju i razvijaju se određeni kognitivni, metakognitivni i motivacijski procesi.

Istraživanje, međutim, ima i neka ograničenja<sup>71</sup> koja treba uzeti u obzir pri razmatranju rezultata istraživanja i njegovih implikacija.

Jedno od vjerojatno najistaknutijih ograničenja rada vezuje se uz ograničene mogućnosti generaliziranja nalaza istraživanja na druge skupine i druge situacije učenja. To se

---

<sup>71</sup> O nekim specifičnim ograničenjima rada raspravljano je u sklopu rasprava vezanih uz pojedino poglavlje rezultata. Ovdje su opisana opća ograničenja rada koja utječu na mogućnost istraživanja da odgovori na istraživačka pitanja.

ograničenje, u dijelu generalizacije na druge skupine, vezuju uz korištenje relativno malog uzorka učenika i primjenu strategije namjernog uzorkovanja učenika. Iako korištenje ovakvog uzorka zasigurno osigurava manju mogućnost generaliziranja nalaza istraživanja u odnosu na neki (veći) probabilistički uzorak, primijenjeni postupak uzorkovanja i odabrana veličina uzorka mogu se opravdati iz pozicija postavljenog cilja istraživanja i eksplorativne prirode istraživanja. Naime, kako istraživanje nije postavljeno kao testiranje nekog teorijskog modela samoregulirajućeg istraživačkog učenja (kad takav model zasad niti ne postoji!), već u cilju ispitivanja odnosa između pojedinih sastavnica istraživačkog učenja i njihove uloge u istraživačkom učenju uključuje elemente više različitih teorijskih perspektiva te prikuplja i (kvantitativno i kvalitativno) analizira podatke iz više izvora, može se tvrditi da u ovoj ranoj eksplorativnoj fazi ispitivanja samoregulirajućih istraživačkog učenja, cilj niti nije statistička (vanjska) generalizacija, već tzv. analitička ili teorijska generalizacija (Yin, 1994). Za razliku od statističke generalizacije koja se odnosi na mogućnost poopćavanja nalaza istraživanja s uzorka na populaciju, analitička se generalizacija odnosi na mogućnost proširivanja ili razvijanja teorijskih propozicija na kojima se temelji rad. Može se tvrditi da se mogućnost analitičke generalizacije ostvaruje čvrstim utemeljenjem istraživanja na postojećim teorijskim razmišljanjima i rezultatima dosadašnjih istraživanja, smještanjem nalaza istraživanja u okvire postojećih spoznaja i njihovim korištenjem za potvrđivanje i nadograđivanje postojećih teorijskih propozicija.

Pitanje generalizacije nalaza istraživanja na druge skupine ostaje, međutim, otvoreno. U metodološkom poglavlju (poglavlju 4.1. *Ispitanici*) šire su argumentirani napravljeni metodološki izbori pri izboru ispitanika, a ovdje je dovoljno istaknuti da uzorkovanje maksimalnog razlikovanja (kao vrste namjernog uzorkovanja) predstavlja dobar izbor za istraživanja s malim brojem ispitanika, budući da se određena reprezentativnost uzorka osigurava uzorkovanjem «informativski bogatih» slučajeva koji odražavaju maksimalni varijabilitet koji postoji u populaciji na ključnim dimenzijama za predmet istraživanja (Patton, 1990).

Od uzorkovanja maksimalnog razlikovanja veći problem za generalizaciju nalaza vjerojatno predstavlja veličina korištenog uzorka, iako ona nalazi svoje opravdanje u usmjerenosti istraživanja na dubinsko ispitivanje procesa promjena u istraživačkom učenju, kao i u praktičnim mogućnostima izvedbe istraživanja. Može se, međutim, tvrditi da relativno mali N na temelju kojeg su provedene usporedbe unutar ispitanika, a posebice one između-ispitanika, ograničava snagu provedenih statističkih testova. Činjenica da se

mnogo opaženih razlika pokazuje statistički neznačajnima usprkos srednje visokim pokazateljima veličine učinaka ukazuje na potrebu opreznog interpretiranja rezultata istraživanja i uvažavanja mogućnosti da neke razlike nisu otkrivene ili proglašene statistički značajnima upravo zbog male veličine uzorka.

Veličina uzorka predstavlja ograničenje koje se očituje i u nemogućnosti korištenja određenih statističkih postupaka. Iako su neparametrijski testovi predstavljali zadovoljavajuće rješenje za odgovaranje na istraživačka pitanja, korištenje nekih složenijih analitičkih postupaka (npr. analize traga, modeliranja latentne krivulje rasta) dalo bi novu, dodatnu vrijednost ispitivanju procesa promjena, jer bi omogućilo otkrivanje putova promjena, utvrđivanje međudnosa različitih aspekata promjena i ispitivanje prediktivnih učinaka pojedinih čimbenika na određene parametre promjena (Niemivirta, 2006; Niemivirta i Tapola, 2007; Cheshire i sur., 2007). Korištenje modeliranja podataka, osim veličine uzorka, ograničava i činjenica da se prikupljeni podaci nalaze na različitim razinama mjerenja; neke su varijable kategorijalne, neke ordinalne, a tek neke (uvjetno) intervalne.

Ograničena mogućnost generalizacije nalaza na druge situacije učenja povezuje se, pak, s činjenicom da je u istraživanju istraživačko učenje ograničeno na rad na jednom zadatku u relativno kontroliranim (izvanučioničkim) uvjetima. Korištenje ovakvog istraživačkog pristupa omogućava veću kontrolu istraživačkih procesa, ali stvara donekle artificijelnu situaciju učenja koja je udaljena od složenog razrednog okruženja u kojem se školsko učenje inače odvija. Imajući na umu kontekstualiziranost i složenost procesa učenja, moguće je pretpostaviti da bi u drugačijem okruženju (npr. uz postojanje distraktora, uz mogućnost odgađanja učenja, uz mogućnost suradnje s drugim učenicima ili uz uvođenje ocjena) učenici drugačije reagirali na istraživački zadatak i pokazivali drugačije obrasce samoregulacije. Jednako tako, može se tvrditi da dobiveni rezultati istraživanja nisu ograničeni samo na korištenu specifičnu situaciju učenja, nego i uz specifičan domenski zadatak. Moguće je pretpostaviti da bi korištenje zadatka iz drugog područja dovelo do ponešto drugačijih rezultata o stjecanju znanja i razvijanju istraživačkih vještina i strategija, budući da rezultati istraživačkog učenja vjerojatno ovise o poznatosti područja, postojanju i elaboriranosti učeničkih prethodnih teorija o predmetu ispitivanja i interesu za predmet.

Na budućim je istraživanjima da ispitaju koliko i kako procesi i ishodi istraživačkog učenja ovise o zadatku i situaciji učenja.

Sljedeće ograničenje rada, koje je imanentno svim istraživanjima koja ispituju subjektivno iskustvo učenika za vrijeme učenja, vezuje se uz probleme mjerenja tih promjenjivih stanja. U literaturi se mnogo raspravlja o ovoj temi. Ainley i Patrick (2006) ističu da zahvaćanje trenutnih promjena u situacijski specifičnim samoregulirajućih procesima zahtijeva da korišteni mjerni instrumenti budu uklopljeni u zadatak i da se njihova primjena odvija bez ometanja procesa učenja, pažnje i koncentracije i bez produžavanja trajanja rada na zadatku, a Efklides (2006a) dodaje da višedimenzionalna, nestabilna i promjenjiva priroda subjektivnih iskustava traži primjenu više mjera i njihovo ponavljanje tijekom rada na zadatku.

U istraživanju su slijeđene ove ideje, pa je za mjerenje metakognitivnog doživljaja i motivacijskih i emocionalnih reakcija učenika na zadatak korišteno više mjera s jednom česticom (procjena interesa za zadatak, procjena težine zadatka itd). Te su mjere za vrijeme rada na zadatku ponavljane nakon svakog četvrtog provedenog eksperimenta, kako bi se pratile promjene u učeničkim iskustvima rada na zadatku. Iako se mjerenje ovih stanja za vrijeme učenja nastojalo olakšati smanjivanjem broja procjena (u odnosu na mjerenje motivacije i metakognitivnog doživljaja prije i poslije rada na zadatku) i kratkim trajanjem primjene ovih mjera, moguće je pretpostaviti da su ova mjerenja ponekad prekidala učenike u produktivnom razmišljanju o rezultatima provedenih eksperimenata i ometala uspostavljeni tijekom eksperimentiranja. Događalo se da su učenici zbog mjerenja motivacijskog i emocionalnog stanja prekidani u tijeku izvođenja planova koji su uključivali izvedbu nekoliko eksperimenata u nizu, što ih je moglo odvratiti od dovršavanja plana i povezivanja susjednih eksperimenata.

Kako bi se osiguralo nesmetano odvijanje procesa učenja, vjerojatno je potrebno mjerenje motivacijskog i emocionalnog stanja učenika za vrijeme učenja bolje uklopiti u rad na zadatku, primjerice putem integriranja mjerenja u računalno okruženje unutar kojeg se odvija učenje.

Neovisno o mogućoj interferenciji mjerenja učeničkih doživljaja za vrijeme učenja s procesima učenja, pojavljuje se pitanje metrijskih karakteristika korištenih mjera motivacije i metakognitivnog doživljaja s jednom česticom. Neke se mjere pokazuju nedovoljno diskriminativnim (osjetljivim), budući da ne uspijevaju pokazati suptilne promjene u učeničkim iskustvima rada na zadatku. O tome govori uski raspon procjena koje učenici daju u svim mjerenjima, kao i njihova relativna stabilnost unutar pojedinih situacija učenja.

Pitanje pouzdanosti i valjanosti mjera je komplicirano činjenicom da klasične vrste pouzdanosti i valjanosti nisu primjenjive kad se radi o mjerama misli i osjećaja koje učenici imaju u pojedinim trenucima rada na zadatku (Ainley i Hidi, 2002; Ainley i Patrick, 2006). Određivanje pouzdanosti i valjanosti mjera promjenjivih stanja s jednom česticom se stoga temelji na unutarnjem (sadržajnom) značenju primijenjenih mjera i na utvrđivanju konvergentnih i diskriminativnih odnosa s drugim mjerama.

Sadržajna analiza pojedinih mjera korištenih u ovom istraživanju pokazuje da su one dovoljno usko definirane, jednodimenzionalne i jednoznačne za ispitanike, a uvjerenje u njihovu valjanost je dodatno ojačano činjenicom da mjere međusobno koreliraju na predvidljiv (teorijski očekivan) način. Stoga se može tvrditi da, usprkos navedenim nedostacima, korištene mjere motivacije, emocija i metakognitivnog doživljaja uspijevaju osigurati točne i valjane informacije o učeničkim subjektivnim iskustvima rada na zadatku istraživačkog učenja.

Konačno, metodološkim ograničenjem rada može se smatrati i temeljenje značajnog broja kognitivnih i metakognitivnih mjera na verbalnim samoiskazima koje učenici daju tijekom rada na zadatku. Ti se verbalni samoiskazi pojavljuju kao odgovori na pitanja koja postavlja istraživačica ili kao spontani iskazi nastali kao rezultat zahtjeva «misli naglas». Pokazuje se da se učenici razlikuju u sposobnosti verbalizacije vlastitih misli i doživljaja koji prate rad na zadatku istraživačkog učenja; dok neki učenici spontano daju mnogo iskaza o tome što rade, što zaključuju, što misle i osjećaju tijekom rada na zadatku, neki učenici teško verbaliziraju vlastite procese učenja i potrebno ih je neprestano poticati. Osim toga, potvrđuje se nalaz drugih istraživanja (Ericsson i Simon, 1993) o tome da učenici prestaju govoriti onda kad počinju doživljavati poteškoće u tijeku procesiranja, vjerojatno onda kad intenzivno razmišljanju, primjerice kad opaze neke disonantne nalaze koje ne uspijevaju odmah interpretirati. Ovakva opažanja sugeriraju mogućnost da su procjene nekih učeničkih kognitivnih i metakognitivnih vještina podcijenjene, posebice za neke učenike, ali govore i o opravdanosti kombiniranja verbalnih mjera s opažanjem rada učenika na zadatku i s praćenjem tragova učeničkih aktivnosti, u cilju postizavanja veće valjanosti mjerenja učeničkih istraživačkih kapaciteta.

Na kraju, može se reći da je ovo poglavlje ukazalo na neke metodološke nedostatke rada koje treba uzeti u obzir u raspravi o rezultatima i implikacijama istraživanja, ali je i pokazalo da su pojedina metodološka ograničenja uzeta u obzir već pri osmišljavanju i provedbi istraživanja, kroz korištenje različitih podataka i različitih metoda prikupljanja

podataka, kao i kroz kombiniranje kvantitativnog i kvalitativnog analitičkog pristupa. Stoga se može tvrditi da istraživanje uspijeva ostvariti svoj osnovni cilj i odgovoriti na pitanja o promjenama procesa istraživačkog učenja u ponavljanim situacijama učenja i o ulozi metakognitivnih i motivacijskih čimbenika u procesima i ishodima istraživačkog učenja.

## **6.2. Odgovori na istraživačka pitanja**

### ***1. Kako se u funkciji ponavljanih izlaganja situacijama učenja razvijaju pojedine sastavnice istraživačkog učenja?***

Rezultati istraživanja pokazuju da se kroz sudjelovanje učenika u četiri situacije istraživačkog učenja i rad na jednom zadatku postižu promjene u korištenju istraživačkih i metakognitivnih vještina i strategija, stječu metakognitivna znanja o cilju i strategijama rada na zadatku, kao i znanja o kauzalnoj strukturi modela zadatka.

Od prvog do četvrtog mjerenja dolazi do sljedećih promjena u korištenju istraživačkih, kognitivnih i metakognitivnih, vještina i strategija:

- × Učenici napreduju u planiranju i organiziranju rada na zadatku. Napuštaju lokalno ulančavanje eksperimenata i približavaju se izvođenju planova koji uzimaju u obzir cjelokupnu strukturu prostora eksperimenata.
- × Učenici češće izvode pojedine eksperimente planski i izražavaju namjeru izvođenja eksperimenata s ciljem analize učinka pojedinog čimbenika. Iako napuštaju inženjerski pristup izvođenja eksperimenata s ciljem generiranja određenih ishoda, učenici često eksperimentiranje započinju biranjem kombinacije čimbenika koja donosi minimalno uništenje šuma, jer im ona služi kao referentni eksperiment za usporedbu s drugim eksperimentima.
- × Učenici češće postavljaju hipoteze o učincima čimbenika na uništenje šuma. Povećava se broj ekskluzivnih i interakcijskih hipoteza, a broj inkluzivnih hipoteza je općenito veći, ali stabilan.
- × Učenici između susjednih eksperimenata mijenjaju u prosjeku manji broj čimbenika, što indicira veće korištenje strategije kontrole varijabli i sustavnije eksperimentiranje.
- × Nema promjena u pokrivanju prostora eksperimenata – učenici u svim mjeranjima izvode podjednak broj (spontanih, jedinstvenih, ponavljanih) eksperimenata.



- × Nema promjena niti u korištenju potpornih alata FILE-a, što sugerira podjednako korištenje metakognitivnih vještina praćenja u svim mjerenjima.
- × Povećava se valjanost inkluzivnih zaključaka. Učenici na početku rada donose mnogo nevaljanih inkluzivnih zaključaka. Broj tih zaključaka se smanjuje kroz mjerenja, što za posljedicu ima smanjivanje ukupnog broja inkluzivnih zaključaka, te rast njihove valjanosti.
- × Broj ekskluzivnih zaključaka je stabilan kroz mjerenja, kao i njihova valjanost. Na početku rada na zadatku učenici donose mnogo manje ekskluzivnih zaključaka nego inkluzivnih, ali je valjanost ekskluzivnih zaključaka tada značajno veća. Od prvog do četvrtog mjerenja ujednačuje se broj i valjanost ekskluzivnih i inkluzivnih zaključaka.
- × Broj interakcijskih zaključaka je malen i stabilan kroz mjerenja. Valjanost interakcijskih zaključaka je niska. Ipak, od prvog do zadnjeg mjerenja raste broj učenika koji su donijeli barem jedan valjani interakcijski zaključak.

Usporedo s razvojem vještina i strategija istraživačkog učenja, učenici stječu znanja o kauzalnoj strukturi modela zadatka. Nakon četiri situacije rada na zadatku, učenici većinom uspješno identificiraju jednostavne (glavne) učinke pojedinih čimbenika na uništenje šuma. Međutim, određeni broj učenika ima poteškoća u svladavanju nelinearnih i interakcijskih učinaka. Pokazuje se da su izvori ovih poteškoća ponešto drugačiji. Dok je neotkrivanje nelinearnog učinka kiselih kiša često posljedica toga što učenici nisu očekivali mogućnost zakrivljenog odnosa, pa su zanemarivali ispitivanje srednje razine varijable 'kisele kiše', problem nerazumijevanja interakcijskog odnosa vrste šuma i nametnika je ponešto složeniji. Veliki dio učenika koji nije prepoznao taj učinak uopće nije imao iskustvo donošenja interakcijskih zaključaka, jer na konceptualnoj razini nisu uviđali mogućnost da učinak nekog čimbenika može biti ograničen ili različit na drugim razinama drugih varijabli. Drugi učenici su postavljali složene teorije o pojedinim čimbenicima, međutim, nisu uvijek znali kako kroz eksperimentiranje pokazati mogućnost interakcijskog odnosa. Analiza donošenja interakcijskih zaključaka ukazuje na poteškoće koje učenici imaju u koordiniranju usporedbe više eksperimenata (u izvedbi dvostrukih kontroliranih usporedbi), u održavanju kontrole nad drugim čimbenicima koji nisu dio ispitivanog interakcijskog odnosa i u održavanju fokusiranosti na utvrđivanje interakcijskog učinka (umjesto skretanja na zaključivanje o učinku drugog čimbenika).

Rezultati istraživanja također pokazuju da uslijed rada na zadatku dolazi do napredovanja učenika u metakognitivnom znanju. Od početnog dominantnog razumijevanja zadatka kao onog u kojem učenik treba ostvariti pozitivan ishod dolazi se do shvaćanja potrebe analize učinaka čimbenika koji dovode do ishoda. Učenici napreduju i u razumijevanju strategija rada na zadatku. Značajan dio učenika stječe razumijevanje potrebe korištenja strategije 'variraj jednu varijablu u jednom trenutku', ali se gotovo polovina učenika i poslije rada na zadatku zadržava na najnižoj razini, onoj koju označava nemogućnost opisivanja bilo kakve strategije. Veće napredovanje u metakognitivnom razumijevanju cilja zadatka u odnosu na razumijevanje strategija rada tumači se mogućnošću da pitanja koja istraživačica postavlja učenicima tijekom rada na zadatku predstavljaju znakove za razumijevanje cilja (a ne i strategija), kao i mogućnošću da metastrateško razumijevanje postoji, ali nije eksplicitno.

Rezultati ovog istraživanja, koji pokazuju da je sudjelovanje učenika u situacijama koje od njih zahtijevaju samostalno eksperimentiranje i kauzalno zaključivanje dovoljan poticaj za generiranje novih, valjanijih istraživačkih pristupa i napredovanje na meta razini, u skladu su s nalazima drugih mikrorazvojnih istraživanja (Kuhn i sur., 1992, 1995; Schauble, 1990, 1996). Tri se elementa smatraju važnima za objašnjenje promjena u učenju u ovakvim situacijama. Kao prvo, promjene istraživačkih pristupa se mogu pojaviti kroz uvježbavanje istraživačkih vještina i strategija, te kao posljedica jačanja metastrateških znanja i vještina. Kao drugo, učenje mogu potaknuti informacije o stvarnom stupnju uništenja šuma u pojedinim kombinacijama čimbenika, koje učenici primaju tijekom rada na zadatku. Kao treće, pitanja koja se postavljaju učenicima tijekom rada o tome što rade i što misle u pojedinim trenucima mogu učenicima poslužiti kao znakovi o strateškim zahtjevima, te kod njih potaknuti refleksivnije, analitičnije i sustavnije pristupanje zadatku. Zahtjev da učenik tijekom rada na zadatku «misli naglas» također tomu pogoduje. Ovo istraživanje, međutim, ne može razlučiti koji su od navedenih uvjeta doista odgovorni za opažene promjene u procesima učenja, pa ostaje na nekim budućim istraživanjima da razdvoje i zasebno ispituju ove moguće utjecaje.

Osim što rezultati istraživanja govore o napredovanju učenika u znanjima, vještinama i strategijama istraživačkog učenja na razini prosječnih vrijednosti, oni upućuju na postojanje značajnih interindividualnih razlika u svim mjerama i u svim mjerenjima. Dok neki učenici već na početku rada na zadatku iskazuju orijentiranost na ispitivanje pojedinih čimbenika, sustavno eksperimentiraju i donose uglavnom valjane inkluzivne i ekskluzivne

zaključke (te i poneke interakcijske zaključke), neki učenici sve do kraja istraživanja eksperimentiraju s ciljem generiranja pojedinih ishoda, ne postavljaju hipoteze, uglavnom ne koriste strategiju kontrole varijabli i većim dijelom nevaljano zaključuju o odnosima između nezavisnih i zavisnih varijabli. Većinu ispitanika ipak karakterizira korištenje i valjanih i nevaljanih istraživačkih pristupa kroz sva četiri mjerenja, iako oni općenito napreduju u korištenju valjanih pristupa. Svi su učenici sposobni izvesti barem poneku valjanu usporedbu i donijeti valjani zaključak o učinku nekog čimbenika, no često se vraćaju na nevaljano eksperimentiranje i zaključivanje. Nema naglog i nepovratnog prijelaza s nevaljanog na valjano eksperimentiranje i zaključivanje, već se valjane strategije postupno ugrađuju u repertoar istraživačkih pristupa, a nevaljane strategije polako slabe. Pokazuje se da učenici relativno rano (već u prvom mjerenju) pokazuju prve valjane zaključke, ali svejedno sve do kraja istraživanja zadržavaju barem poneki nevaljani zaključak. Čak i uspješni učenici, oni koji postižu visoku razinu strateške izvedbe već na početku rada na zadatku, ne uspijevaju konzistentno koristiti valjane strategije kroz sve eksperimente. Ovi nalazi sugeriraju da najveći izazov za učenike u istraživačkom učenju ne predstavlja svladavanje izvođenja novih valjanih strategija, nego ukidanje onih starih i nevaljanih.

Analiza slučajeva šest učenika također ukazuje na značajne intraindividualne varijacije u eksperimentiranju i zaključivanju tijekom rada na zadatku. Učenici unutar istih mjerenja, u susjednim eksperimentima, paralelno koriste različite istraživačke pristupe, od kojih su neki valjani, a neki nevaljani. Događa se da čak i u istom eksperimentu učenik donese valjani zaključak o učinku jednog čimbenika, a nevaljani zaključak o učinku drugog čimbenika.

Nalazi o značajnom inter- i intraindividualnom varijabilitetu također su tipični nalazi mikrorazvojnih istraživanja (Kuhn i sur., 1992, 1995; Schauble, 1990, 1996).

Rezultati ovog istraživanja također pokazuju da se ostvareni napredak (na razini prosjeka skupine) očituje tijekom prve dvije situacije učenja, dok se već u trećem mjerenju uglavnom uspostavlja konačna razina. Ta je razina daleko od optimalne. Čak i u zadnjem mjerenju učenici izvedu mnogo eksperimenata bez hipoteza, a doneseni jednostavni zaključci (i inkluzivni i ekskluzivni) su i dalje značajnim dijelom doneseni na nevaljani način, na temelju usporedbe nekontroliranih eksperimenata. Uz to, učenici ne uspijevaju na transfernom zadatku koji traži primjenu metakognitivnog znanja pokazati svoje poboljšano

razumijevanje cilja i strategija rada na zadatku, već se vraćaju na zagovaranje inženjerskog pristupa eksperimentiranju.

Ovi nalazi sugeriraju da, za ostvarivanje snažnijih promjena, napredovanje svih učenika i transfer na nove situacije učenja, nije dovoljno pustiti učenike u nekoliko situacija samostalnog eksperimentiranja. Rad na zadatku, koji se događa bez jasne povratne informacije o tome koliko uspješno učenici stječu znanja o kauzalnoj strukturi zadatka i koliko valjano zaključuju, kao i bez nekih drugih direktnijih poticaja usmjerenih na jačanje strateških i metastrateških vještina, očito nije dovoljan za stjecanje potpunog znanja o kauzalnoj strukturi modela zadatka, kao i za uspostavljanje obrazaca konzistentnog korištenja valjanih strategija eksperimentiranja i zaključivanja.

## ***2. Kakva je povezanost metakognitivnog znanja i metakognitivnih vještina s istraživačkim vještinama i učinkom na zadatku istraživačkog učenja?***

Istraživanje pokazuje da je uspješno strateško djelovanje na zadatku istraživačkog učenja nemoguće bez postizanja određene razine metakognitivnog razumijevanja, barem one koju označava razumijevanje potrebe analize «*toga što utječe na uništenje šuma*». Pokazuje se, nadalje, da je strateški uspjeh moguć čak i ako je eksplicitno metastrateško razumijevanje na niskoj razini, ukoliko postoji ova analitička usmjerenost koju osigurava razumijevanje cilja zadatka.

Iako učenici koji postižu više razine metakognitivnog znanja u prosjeku više koriste strategiju kontrole varijabli, ostvaruju veću valjanost zaključaka i bolje razumijevanje kauzalne strukture modela zadatka od učenika koji postižu niže razine metakognitivnog znanja, potpuno metakognitivno razumijevanje ne jamči postizanje strateškog uspjeha. Time se potvrđuje da razvijeno metakognitivno razumijevanje jest nužan, ali ne i dovoljan uvjet ostvarivanja strateškog uspjeha. Učenici mogu znaju da je cilj utvrditi učinak pojedinih čimbenika na uništenje šuma ili razumjeti potrebu sustavnog i strateškog djelovanja, ali ipak provoditi eksperimente na neorganiziran i nesustavan način, ili tako da valjane strategije ne koriste konzistentno. Kao što se vidi iz odgovora na zadnje istraživačko pitanje, razlozi nekorištenja metakognitivnog znanja mogu biti motivacijski, ali vjerojatno i metakognitivni, ukoliko učenik nema razvijene proceduralne vještine planiranja, praćenja, vrednovanja i regulacije procesa učenja.

Rezultati istraživanja doista i pokazuju da je planiranje i organiziranje rada na zadatku povezano s uspješnošću učenja. Učenici koji na zadatku istraživačkog učenja rade po

općem planu koriste prikladnije, valjanije strategije eksperimentiranja i zaključivanja i stječu više znanja o kauzalnoj strukturi modela zadatka od učenika koji lokalno ulančavaju susjedne eksperimente. Korištenje FILE-ovih potpornih alata koji upućuju na metakognitivno praćenje rezultata eksperimenata i organiziranje eksperimenata na način koji olakšava njihovu usporedbu povezano je, pak, s točnošću predviđanja rezultata eksperimenata (doduše, samo u prva dva mjerenja). Ovi nalazi pokazuju da korištenje metakognitivnih vještina određuje kvalitetu istraživačkog učenja i sugeriraju da rezultati učenja ovise o tome koliko učenik planira učenje, koliko sustavno eksperimentira i koliko metakognitivno prati i upravlja vlastitim procesom učenja.

Ovi nalazi potvrđuju rezultate drugih istraživanja (Veenman i sur., 2004; Veenman i Spaans, 2005), ali i proširuju spoznaje o važnosti metakognitivnih vještina u procesima istraživačkog učenja, budući da, za razliku od ovih istraživanja koja počivaju na jednokratnim primjenama zadatka istraživačkog učenja u FILE programu, pokazuju da metakognitivni procesi nisu važni samo u početnom učenju (prvoj situaciji učenja), već i kasnijim fazama učenja.

Kvalitativni nalazi o međuodnosu strateškog djelovanja i meta razine daju daljnju potporu važnosti metakognitivnih procesa u određivanju tijeka i rezultata istraživačkog učenja.

Na početku rada na zadatku, učenici, u skladu s vlastitim početnim razumijevanjem cilja i strategija rada na zadatku, započinju eksperimentiranje s ciljem postizanja pozitivnih ishoda ili s ciljem otkrivanja učinaka do kojih dovode različite kombinacije čimbenika. Kod učenika koji već u prvom mjerenju ostvaruju strateški uspjeh, odmah dolazi do jačanja meta razine na temelju povratnih informacija o primjeni istraživačkih strategija. Korištenje nevaljanih strategija eksperimentiranja i zaključivanja jača razumijevanje neprikladnosti i neupotrebljivosti tih postupaka za odgovaranje na istraživačičina pitanja *«Što si zaključio o utjecaju čimbenika na uništenje šuma?»*, što vodi metastrateškoj potrazi za novim pristupima. Isto tako, korištenje valjanih strategija eksperimentiranja i zaključivanja vodi većoj metakognitivnoj svjesnosti tako što učenici počinju uviđati vrijednost i upotrebljivost tih strategija za ostvarivanje cilja. Napredovanje u razumijevanju cilja i toga koliko je cilj ostvaren pomoću pojedinih strategija povratno potiče odabir valjanijih istraživačkih strategija i vodi uspješnijoj strateškoj izvedbi.

Kod učenika koji tijekom rada na zadatku postižu napredak u strateškom djelovanju, opaža se sporije usporedno jačanje strateškog djelovanja i metastrateškog razumijevanja.

Pokazuje se da veliku važnost u jačanju valjanosti eksperimentiranja i zaključivanja ima zauzimanje sve sustavnijeg pristupa eksperimentiranju i poboljšano planiranje i organiziranje učenja u kasnijim fazama učenja. Ovi učenici u prvim mjerenjima koriste neučinkovit pristup i provode eksperimente bez plana, nesustavno i bez namjere analize učinka pojedinih čimbenika. U sljedećim mjerenjima napreduju preko eksperimentiranja s ciljem generiranja određenih ishoda do analize učinaka pojedinih čimbenika, pritom koristeći sve sustavniji, analitičniji i reflektivniji pristup. Prve valjane zaključke oni donose neplanskim i nenamjernim valjanim variranjem varijabli između eksperimenata, u kontekstu provedbe eksperimenata s ciljem generiranja određenih ishoda ili nakon dobivanja nekih neobičnih i neočekivanih rezultata. S provođenjem prvih valjanih usporedbi i donošenjem prvih valjanih zaključaka, ovi učenici postepeno počinju shvaćati vrijednosti pristupa ispitivanja učinaka pojedinih čimbenika u odnosu na pristup eksperimentiranja s ciljem generiranja određenih ishoda. Postepeno počinju uočavati i prednosti koje donosi sustavno variranje čimbenika za razumijevanje odnosa među varijablama (što izražavaju riječima *«sad ću sve isto, ali ću promijeniti vrstu šume»*). Povećana svjesnost na meta razini vodi primjeni boljih strategija i dovodi do promjena u korištenju strategija koje se opažaju na razini izvedbe, pa ovi učenici u zadnjim mjerenjima planiraju slijed eksperimenata, „rade po redu“, ispituju učinak pojedinih čimbenika i namjerno koriste valjano variranje čimbenika između pojedinih eksperimenata.

Kod učenika koji na zadatku ne ostvaruju strateški uspjeh, događa se da neprikladno metakognitivno razumijevanje zahtjeva zadatka, nedostatna svijest o potrebi sustavnog i planiranog eksperimentiranja, kao i nedovoljno metakognitivno praćenje i reguliranje rada na zadatku tijekom cijelog istraživanja ograničavaju strateško napredovanje i stjecanje znanja o odnosima između varijabli. Iako su i ovi učenici sposobni povremeno izvesti valjane strategije eksperimentiranja i zaključivanja, nedostatna meta razina i primjena neplanskog, nesustavnog, neanalitičkog i nerefleksivnog istraživačkog pristupa kod njih koči razvoj valjanog eksperimentiranja i zaključivanja.

### ***3. Razlikuju li se, i na koji način, različiti motivacijski profili učenika u procesima učenja i učinku na zadatku istraživačkog učenja?***

Na temelju prospektivnog doživljaja zadatka (motivacijskih, emocionalnih i metakognitivnih procjena prije rada na zadatku u svakom od četiri mjerenja) učenici su grupirani u tri klastera. Jedan je klaster predstavljao učenike pozitivne motivacijske

orijentacije, a dva su klastera činili učenici negativnije motivacijske orijentacije, koji su se međusobno razlikovali po pozitivnosti emocionalnih procjena.

Na temelju teorijskih razmatranja i empirijskih nalaza o utjecaju motivacije na procese i ishode istraživačkog učenja u zadacima u kojima učenici imaju slobodu izbora istraživačkog pristupa i sami određuju tijek i trajanje učenja (Vollmeyer i Rheinberg, 2000, 2005, 2006; Vollmeyer i sur., 1997; Rheinberg i sur., 2000, 2002, 2005), očekivalo se da će učenici pozitivne motivacijske orijentacije koristiti kvalitetnije istraživačke pristupe, sustavnije i valjanije eksperimentiranje i zaključivanje, pokazivati više metakognitivnih aktivnosti i stjecati više znanja o odnosima između varijabli. Rezultati istraživanja, međutim, pokazuju da između različitih motivacijskih profila (klastera) nema statistički značajnih razlika niti u jednoj mjeri. Učenici različitih motivacijskih orijentacija su, doduše, zadržali razlike u procjenama subjektivnog iskustva rada na zadatku, pa su oni pozitivne motivacijske orijentacije davali povoljnije motivacijske, emocionalne i metakognitivne procjene tijekom učenja u svim mjerenjima, međutim, razlika u istraživačkim pristupima i rezultatima učenja nije bilo.

Nepostojanje razlika između različitih motivacijskih profila učenika u procesima i ishodima istraživačkog učenja na razini prosječnih vrijednosti u pojedinim mjerenjima tumači se malim varijabilitetom mjera<sup>72</sup> na kojima je temeljeno klasteriranje, ali i nekim metodološkim razlozima - zahtjevom izvođenja minimalno deset eksperimenata po mjerenju, nepostojanjem povratne informacije o uspješnosti rada na temelju koje bi učenici mogli formirati svoj doživljaj zadatka, kao i ponavljanjem istih mjera unutar i između pojedinih mjerenja (što kod učenika stvara tendenciju davanja istih procjena).

Osim toga, činjenica da su na mjerama znanja i istraživačkih i metakognitivnih vještina, razlike unutar klastera bile jednake ili čak veće od razlika između klastera, upućuje na potrebu ispitivanja motivacijskih utjecaja uz kontroliranje drugih osobina koje su relevantne za istraživačko učenje, prije svega kognitivnih sposobnosti, ali i metakognitivnih kapaciteta.

Stoga se u istraživanju pristupilo kvalitativnom ispitivanju motivacijskih utjecaja suprotstavljanjem slučajeva šest učenika pozitivnije i negativnije motivacijske orijentacije, koji su međusobno slični po razini strateškog uspjeha na zadatku (po valjanosti jednostavnih zaključaka). Uspoređeni su parovi učenika koji ne ostvaruju strateški uspjeh

---

<sup>72</sup> Skupni rezultati svih učenika pokazuju izrazito pozitivne prosječne procjene i male raspone tih procjena.

na zadatku do kraja istraživanja, parovi učenika koji ostvaruju značajan napredak na zadatku i parovi učenika koji već na početku istraživanja iskazuju visoku razinu valjanosti zaključivanja. Uz usporedbu parova izjednačenih po strateškoj izvedbi, traženi su zajednički obrasci djelovanja učenika negativnije motivacijske orijentacije, kao i oni učenika pozitivnije motivacijske orijentacije.

Kvalitativna analiza procesa učenja unutar pojedinih mjerenja pokazuje da manifestacije motivacijskih utjecaja mogu biti prilično različite, što je moglo doprinijeti neutvrđivanju razlika između različitih motivacijskih profila učenika u statističkim analizama.

S jedne strane, manjak motivacije za rad na zadatku može voditi odabiru neplanskog i nesustavnog pristupa eksperimentiranju, kao i odabiru nepromišljenog i neanalitičkog pristupa zaključivanja, te pogodovati nekorištenju metakognitivnih vještina praćenja i kontrole istraživačkih aktivnosti. Učenik može izvesti mnogo eksperimenata na brz i nepromišljen način (čak i nasumce), što rezultira mnoštvom nevaljanih zaključaka. S druge strane, manjak motivacije se može očitovati u preranom prekidanju učenja i provedbi premalog broja eksperimenata, što ograničava količinu nalaza koje učenik stvara i onemogućuje sagledavanje svih odnosa među varijablama. U slučaju postojanja visokih strateških i metastrateških kompetencija učenika, manjak motivacije može biti čimbenik koji vodi prebrzoj izvedbi eksperimenata i nekonzistentnoj primjeni valjanih strategija eksperimentiranja i zaključivanja.

Kvalitativna analiza procesa učenja i obrazaca promjena u korištenim strategijama eksperimentiranja i zaključivanja, dakle, oponira rezultatima kvantitativne analize i ukazuje na mogućnost da motivacija može usmjeriti, pospješiti ili ograničiti istraživačko učenje putem mogućih utjecanja na odabir istraživačkog pristupa i na razinu usredotočenosti, posvećenosti i ustrajnosti koju učenik pokazuje pri odabiru eksperimenata i analizi nalaza. Primjer učenika negativne motivacijske orijentacije koji napreduje na zadatku ukazuje na paralelno odvijanje promjena u motivaciji i promjena u pristupu učenju, pa sugerira mogućnost uzajamnog djelovanja ovih procesa - poboljšanje motivacije može uvjetovati promjene u pristupu radu i zauzimanje organiziranijeg i reflektivnijeg pristupa, a promjene u istraživačkom pristupu i uspjeh koji iz toga proizlazi mogu poticati promjene u motivaciji.

Ipak, rezultati istraživanja sugeriraju da je motivacija nužan, ali ne i dovoljan uvjet za postizanje uspjeha na zadatku. Osim kognitivnih sposobnosti i sposobnosti izvedbe



istraživačkih strategija i vještina, za napredovanje na zadatku istraživačkog učenja i ostvarenje visoke razine strateške izvedbe ključna je, kao što smo vidjeli, razvijenost metakognicije. Bez metakognicije, nema uspješnog rješavanja zadatka istraživačkog učenja, čak i uz visoku motivaciju. Slučaj motiviranog učenika koji postiže loš rezultat na zadatku pokazuje da je neučinkovit i nepromišljen istraživački pristup koji on zauzima na zadatku posljedica njegovih metakognitivnih deficita, prije svega nemogućnosti kontinuiranog praćenja rada na zadatku, koordiniranja provedbe eksperimenata i ograničavanja vlastitog teorijski motiviranog zaključivanja. Visoke rezultate na zadatku istraživačkog učenja je, pak, moguće ostvariti čak i bez visoke motivacije, ali je u takvim uvjetima teško očekivati konzistentnu primjenu valjanih metoda eksperimentiranja i zaključivanja u situacijama ponavljanog rada na istom zadatku. Učenik koji brzo postiže visoku razinu strateške izvedbe ima poteškoća u održavanju motivacije za nastavljanje rada na zadatku, pa u kasnijim fazama rada pokazuju i blago nazadovanje u korištenim pristupima eksperimentiranju i zaključivanju. Da bi se postigla konzistentna uporaba valjanih strategija eksperimentiranja i zaključivanja, nije dovoljno imati samo visoke sposobnosti primjene tih vještina, prikladno metakognitivno znanje o zahtjevima zadatka i strategijama potrebnima za njegovo rješavanje, kao i metakognitivne vještine odabira, praćenja i regulacije korištenja tih strategija u pojedinim situacijama učenja. Potrebno je samoregulirati vlastitu motivaciju i emocije i održati visoku razinu usredotočenosti, analitičnosti, kao i spremnost investiranja truda u situaciji gubitka interesa za zadatak i doživljavanja zadatka kao neizazovnog.

Na kraju, može se utvrditi da je kvalitativna analiza procesa učenja otvorila važna pitanja interakcije metakognitivnih i motivacijskih procesa u istraživačkom učenju i ponudila neke hipoteze. Ta su pitanja dosad bilo potpuna zanemareno u istraživanjima istraživačkog učenja, pa ostaje na budućim istraživanjima testirati te hipoteze.

### **6.3. Implikacije za buduća istraživanja**

Ovo istraživanje, kao eksplorativno istraživanje, pokušalo je obuhvatiti samoregulirajuće istraživačko učenje u njegovoj cjelovitosti, široko zahvatiti pojedine kognitivne, metakognitivne i motivacijske procese te ispitati njihovu ulogu u stjecanju znanja i razvijanju valjanih istraživačkih pristupa. Za odgovaranje na taj cilj, istraživanje je obuhvatilo uzorak učenika koji reprezentiraju širok raspon sposobnosti, postignuća i interesa relevantnih za rad na zadatku istraživačkog učenja, a varijabilitet njihovih

postignuća na zadatku nije ograničilo uvođenjem bilo kakvih intervencija ili manipulacija. Kao takvo, istraživanje je otvorilo brojna pitanja na koja nije bilo moguće odgovoriti, te potaknulo razmišljanja o mogućim smjerovima budućih istraživanja. Jedan od smjerova vjerojatno uključuje usmjeravanje istraživačkih napora na specifičnije i ograničenije istraživanje pojedinih varijabli i pojedinih odnosa obuhvaćenih prvim istraživanjem, uz korištenje većih uzoraka učenika i istraživačku kontrolu nekih procesa (npr. kognitivnih sposobnosti). Drugi, potpuno drugačiji smjer predstavlja provođenje istraživanja o procesima istraživačkog učenja u naturalističkom (razrednom) okruženju, dok treći smjer podrazumijeva intervencijske studije učinkovitosti određenih programa za poticanje valjanih istraživačkih pristupa i njihovog transfera u druge situacije učenja.

Na temelju rezultata ovog istraživanja, moguće je predložiti koncentriranje budućih istraživanja oko sljedećih istraživačkih pitanja ili tema:

1. Kakvi su obrasci promjena u pojedinim procesima istraživačkog učenja između i unutar ispitanika, koliko su promjene u pojedinim varijablama povezane s promjenama u drugim varijablama (npr. koliko su promjene u metastrateškom znanju povezane s promjenama u korištenju strategije kontrole varijabli), koji su individualni i situacijski prediktori različitih obrazaca promjena (razine i stope promjena), koliko se na temelju različitih obrazaca promjena mogu predvidjeti razlike u rezultatima učenja.
2. Kako su procesi i ishodi istraživačkog učenja povezani s karakteristikama učenika (dobi, znanjem o području, kognitivnim sposobnostima, motivacijskim dispozicijama), karakteristikama zadatka (područjem, objektivnom težinom) i karakteristikama situacije učenja (trajanjem rada, individualnom-grupnom primjenom, laboratorijskim-razrednim okruženjem).
3. Kojim obrazovnim postupcima, i kako najučinkovitije i trajno potaknuti jačanje istraživačkih vještina i strategija i metakognitivnih znanja i vještina.
4. Koliko, i pomoću kojih elemenata i uvjeta, računalno okruženje doprinosi kvaliteti procesa i ishoda istraživačkog učenja, utječe li korištenje računalne tehnologije na količinu, dubinu i trajnost rezultata učenja i na učinkovitost stjecanja znanja i razvoja istraživačkih vještina, kako se korištenje računalne tehnologije odražava na učeničku motivaciju i interes za istraživanje i znanost.

#### **6.4. Implikacije za obrazovnu praksu**

Rezultati istraživanja prikazani u prethodnim poglavljima imaju više implikacija za obrazovnu praksu.

Istraživanje pokazuje da je istraživačko učenje u računalnom okruženju za učenike motivirajuće, izazovno i poticajno, te upućuje na potrebu šire uporabe računalne tehnologije u procesu školskog učenja i poučavanja u području znanosti.

Korištenje računalne tehnologije je posebice važno jer pomaže uspostavi kvalitetnog istraživačkog učenja. Ono uvodi učenike u aktivnosti koje oponašaju metode znanstvenog istraživanja, pruža im mogućnost sudjelovanja u aktivnostima koje su inače izvan dosega i osigurava stjecanje znanja o području uz istovremeno razvijanje istraživačkih vještina i učenje o prirodi i procesima znanosti.

Ovo istraživanje, međutim, pokazuje da učenici, čak i oni uspješni, nedovoljno koriste potporne alate (programske funkcije FILE-a) koji mogu značajno olakšati rad u programu i potaknuti uspješno učenje. Štoviše, pokazuje se da se korištenje potpornih alata ne mijenja u ponavljanim situacijama učenja - učenici od početka do kraja istraživanja ne napreduju u stupnju iskorištavanja mogućnosti računalnog okruženja, pa se pri analizi rezultata eksperimenata radije oslanjaju na vlastito pamćenje i teorije, nego na mogućnost pregleda rezultata prethodnih eksperimenata putem funkcija selekcije i organizacije eksperimenata.

Činjenica da učenici ne koriste mogućnosti koje im pruža računalno okruženje sugerira da ovo učenje u računalnom okruženju treba dodatnu potporu. Na sreću, računalno okruženje pruža mnogo mogućnosti za poticanje istraživačkog učenja. Moguće je ugraditi različite, specifične potporne alate koji potiču pojedine aspekte samoregulirajućeg učenja. Potporni alati mogu pomoći učenicima u prevladavanju nekih problema s kojima se uobičajeno susreću u situacijama samostalnog eksperimentiranja. Ti alati mogu pomoći podržavanjem određenih istraživačkih aktivnosti, pružanjem potpore u postavljanju istraživačkih pitanja i formuliranju hipoteza, eksperimentiranju, zaključivanju i vrednovanja zaključaka. Osim toga, potporni alati mogu modelirati i poticati učeničke metakognitivne i samoregulirajuće procese tijekom učenja (planiranje, praćenje, donošenje kontrolnih odluka, refleksiju i vrednovanje).

Istraživanje ukazuje da određeni procesi zahtijevaju posebnu potporu. Pozitivno djelovanje na istraživačko učenje zasigurno bi imalo uvođenje kognitivnih alata koji bi učenicima pomogli u postavljanju jasnih istraživačkih pitanja i formuliranju eksplicitnih hipoteza.

Učenicima bi mogao biti prikazan predložak u kojem bi se od njih zahtijevalo određivanje cilja provedbe pojedinog eksperimenta (uz poticaj 'usmjeri se na početku na ispitivanje jedne varijable') i postavljanje hipoteza na temelju unaprijed definiranih varijabli i mogućih odnosa među njima. U fazi eksperimentiranja učenicima bi moglo pomoći prikazivanje upute 'variraj jednu varijablu u jednom trenutku', a u fazi vrednovanja nalaza i zaključivanja koristan bi mogao biti predložak koji bi od učenika zahtijevao usporedbu provedenih eksperimenata, generiranje objašnjenja donesenih zaključaka i reflektivno razmatranje implikacija dobivenih nalaza za učeničke hipoteze i teorije.

Uz podržavanje razvoja istraživačkih vještina i strategija, istraživanje pokazuje da bi ključnu ulogu u poticanju istraživačkog učenja u računalnom okruženju moglo imati ugrađivanje metakognitivnih potpornih alata. Takvi alati bi od učenika mogli zahtijevati postavljanje ciljeva učenja, planiranje i strukturiranje procesa učenja, osiguravanje slijeda odvijanja pojedinih radnji, promišljanje odabira istraživačkog pristupa, sustavno praćenje rezultata eksperimenata, vođenje bilježaka o provedenim eksperimentima i zaključcima, procjenjivanje procesa učenja, vrednovanje rezultata rada itd. Osim navedenog, računalno okruženje bi moglo pomoći istraživačkom učenju osiguravanjem povratnih informacija učenicima o procesima i rezultatima učenja, koje bi učenici mogli iskoristiti za vrednovanje ili prilagođavanje istraživačkih pristupa.

Ipak, pri dizajniranju potpornih alata za istraživačko učenje unutar računalnog okruženja ne treba zaboraviti da je cilj pružanja potpore poticanje samoregulirajućeg učenja, a ne stvaranje «ovisnosti» o vanjskoj regulaciji. Potpora učenju je vjerojatno najvažnija i najučinkovitija u ranim fazama učenja, kad učenik nema dostatno razvijene vještine istraživačkog učenja i vještine samostalnog reguliranja učenja. Kako učenici stječu iskustvo rada na zadatku i razvijaju samoregulacijske vještine, potrebno je potporu prilagoditi tim promjenama (koristiti je samo onda kad je učenicima doista potrebna, kad je učenici sami iniciraju) i postepeno je smanjivati i ukidati.

Ovo istraživanje također pokazuje da učenici napreduju u korištenju istraživačkih i metakognitivnih vještina i strategija, stjecanju znanja o predmetu istraživanja i stjecanju metakognitivnog znanja o cilju i strategijama rada na zadatku, čak i bez direktne vanjske podrške. Sudjelovanje učenika u ponavljanim situacijama istraživačkog učenja i vježbanje istraživačkih vještina je dovoljno za iniciranje promjena na strateškoj i metastrateškoj razini. Napredak se, međutim, događa kod većine, ali ne kod svih učenika. Ovi nalazi imaju također značajne implikacije za obrazovnu praksu. Oni pokazuju da je u

znanstvenom obrazovanju važno učenicima pružiti mnogo prilika za sudjelovanje u istraživačkim aktivnostima jer kroz procese samostalnog eksperimentiranja učenici stječu relevantne vještine i uče o procesima znanosti. Malo je vjerojatno da bi te vještine i uvide učenici mogli steći kroz tradicionalnu predavačku nastavu ili kroz promatranje demonstracijskih pokusa koje izvodi nastavnik. Sudjelovanje u istraživačkim aktivnostima pruža jedinstvenu mogućnost istodobnog jačanja konceptualnog razumijevanja područja/predmeta istraživanja, stjecanja istraživačkih vještina i strategija, razvoja vještina samoregulacije učenja i meta razumijevanja znanstveno-istraživačke djelatnosti, i kao takvo, treba predstavljati središnju aktivnost svakog znanstvenog obrazovanja. Međutim, nedovoljno napredovanje (dijela) učenika i nekonzistentna primjena valjanih istraživačkih pristupa kroz cijelo trajanje istraživanja koju pokazuje većina učenika, sugerira da uvježbavanje istraživačkih vještina i strategija kroz ponavljani rad na istom zadatku nije optimalna metoda poticanja promjena. Iskustva drugih istraživanja (Andersen, 1999, Pearsall, 1999; Kuhn i sur., 2000; Keselman i Kuhn, 2002; Keselman, 2003) ukazuju na učinkovitost intervencija koje direktno potiču jačanje meta razine, kao razine na kojoj se odlučuje koje će istraživačke pristupe učenik primijeniti u određenoj situaciji učenja. Prepoznaje se da u situacijama u kojima učenici samostalno strukturiraju proces učenja i odlučuju o korištenju određenih istraživačkih pristupa, nije važno samo naučiti izvoditi pojedine istraživačke aktivnosti, već i razumjeti kada, kako i zašto ih koristiti u odgovaranju na zahtjeve zadatka, što onda olakšava i transfer istraživačkih vještina na nove situacije učenja. Neki od mogućih putova jačanja metakognitivnog razumijevanja uključuju vođeno reflektiranje i vrednovanje procesa vlastitog učenja ili učenja drugih učenika, raspravljanje o metakognitivnim procesima u parovima ili u skupinama učenika, direktno poučavanje metastrateškog znanja.

Istraživanje, nadalje, pokazuje da učenici relativno uspješno svladavaju jednostavne odnose između varijabli u modelu zadatka, dok im složeniji, interakcijski i nelinearni odnosi predstavljaju problem. Pri osmišljavanju istraživačkih zadataka stoga se važnim čini prilagoditi razinu složenosti zadatka učeničkim mogućnostima razumijevanja i sposobnostima ovladavanja zadatkom. Vjerojatno je opravdano započeti vježbanje istraživačkih vještina i strategija na učenicima zanimljivim sadržajima jednostavne kauzalne strukture koja uključuje mali broj varijabli, kategorijalne varijable, jednostavne odnose među varijablama i nepostojanje pogreške mjerenja (varijabiliteta rezultata). Sa stjecanjem istraživačkog iskustva i razvojem istraživačkih vještina moguće je postepeno

uvoditi složenije kauzalne strukture, interakcijske i nelinearne odnose između varijabli, kontinuirane varijable i pogrešku mjerenja.

Osim teškoća u savladavanju složenih odnosa među varijablama, istraživanje također pokazuje da (neki) učenici imaju problema u razumijevanju odnosa koji se ne slažu s njihovim prethodnim teorijama o učinku određenih čimbenika. Problemi se očituju, s jedne strane, u zanemarivanju ispitivanja tih čimbenika, a s druge strane, u netočnom i nevaljanom interpretiranju rezultata provedenih eksperimenata. Učenici mogu zadržati netočne teorije o tim čimbenicima, čak i onda kad su već pokazali vještine valjanog eksperimentiranja i zaključivanja u ispitivanjima učinaka drugih čimbenika. Nalaz o promjenjivosti učeničkih istraživačkih pristupa ovisno o njihovim teorijskim očekivanjima sugerira da je pri radu na zadatku istraživačkog učenja potrebno osvješćivati proces koordinacije nalaza i učeničkih teorija i razvijati učeničko epistemološko razumijevanje o izvorima i vrstama znanja, procesu stjecanja znanja i razlikama između znanja, vjerovanja, istine i opravdanja. Istraživačke aktivnosti učenika uvijek trebaju biti praćene raspravama, refleksijama i pružanjem pojašnjenja, kako učenici ne bi završili rad na istraživačkom zadatku s krivim zaključcima i krivim konceptualizacijama ispitivanih pojava. Te su rasprave i objašnjenja važni, uostalom, i zato što omogućuju učenicima razvijanje prikladnog znanstvenog rječnika koji je potreban za razumijevanje znanstvenih teorija, opisivanje pojava na znanstveni način i formuliranje empirijski provjerljivih istraživačkih pitanja i hipoteza.

Na kraju, može se reći da rezultati istraživanja o spremnosti učenika za sudjelovanje u istraživačkim aktivnostima pokazuju da je razvijanje vještina znanstvenog razmišljanja ostvariv obrazovni cilj, ukoliko se učenicima osigura prikladna podrška nastavnika i suvremene obrazovne tehnologije. Zbog svoje širine i primjenjivosti u svakodnevnom životu, taj cilj, međutim, nije važan samo za znanstveno obrazovanje, već ga je moguće implementirati u osnovnoškolsko obrazovanje i kao međupredmetni cilj.

## LITERATURA

---

- Abd-El-Khalick, F., BouJaoude, S., Duschl, R. A., Hofstein, A., Lederman, N. G., Mamlok, R., Niaz, M., Treagust, D., i Tuan, H. (2004). Inquiry in science education: International perspectives. *Science Education*, 88(3), 397-419.
- Ainley, M. (2006). Connecting with Learning: Motivation, Affect and Cognition in Interest Processes. *Educational Psychology Review*, 18, 391–405.
- Ainley, M. i Hidi, S. (2002). Dynamic Measures for Studying Interest and Learning. U: P.R. Pintrich i M.L. Maehr (Ur.), *New Directions in Measures and Methods. Advances in Motivation and Achievement (Volume 12)* (str. 43–76). Amsterdam: Elsevier Science Ltd.
- Ainley, M., Hidi, S. i Berndorff, D. (2002). Interest, Learning, and the Psychological Processes that Mediate their Relationship. *Journal of Educational Psychology*, 94(3), 545-561.
- Ainley, M. i Patrick, L. (2006). Measuring Self-regulated Learning Processes through Tracking Patterns of Student Interaction with Achievement Activities. *Educational Psychology Review*, 18, 267–286.
- Ajdković, M. i Kolesarić, V. (Ur.) (2003). *Etički kodeks istraživanja s djecom*. Vijeće za djecu Vlade RH i Državni zavod za zaštitu obitelji, materinstva i mladeži.
- Andersen, C. (1998). *A microgenetic study of science reasoning in social context*. Neobjavljena doktorska disertacija. New York: Teachers College, Columbia University.
- Anderson, R.D. (2002). Reforming Science Teaching: What Research Says about Inquiry. *Journal of Science Teacher Education*, 13 (1), 1–12.
- Anderson, L.W. i Krathwohl, D.R. (Ur.) (2001). *A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives*. New York: Longman.
- Azevedo, R. (2009). Theoretical, conceptual, methodological, and instructional issues in research on metacognition and self-regulated learning: A discussion. *Metacognition and Learning*, 4, 87–95.
- Azevedo, R. (2007). Understanding the complex nature of self-regulatory processes in learning with computer-based learning environments: an introduction. *Metacognition and Learning*, 2, 57–65.
- Azevedo, R. i Hadwin, A.F. (2005). Scaffolding self-regulated learning and metacognition – Implications for the design of computer-based scaffolds. *Instructional Science*, 33, 367-379.

- Beishuizen, J., Wilhelm, P. i Schimmel, M. (2004). Computer-supported inquiry learning: effects of training and practice. *Computers & Education*, 42, 389–402.
- Boekaerts, M.(2002). The On-Line Motivation Questionnaire: A Self-report Instrument to Assess Students' Context Sensitivity. U: P.R. Pintrich, i M.L. Maehr (Ur.), *New Directions in Measures and Methods. Advances in Motivation and Achievement (Volume 12)* (str. 77–120). Amsterdam: Elsevier Science Ltd.
- Boekaerts, M.(1999). Self-regulated learning: where we are today. *International Journal of Educational Research*, 31, 445–457.
- Boekaerts, M.(1997). Self-regulated Learning: A New Concept Embraced by Researchers, Policy Makers, Educators, Teachers, and Students. *Learning and Instruction*, 7(2), 161–186.
- Boekaerts, M. i Cascallar, E. (2006). How Far Have We Moved Toward the Integration of Theory and Practice in Self-Regulation? *Educational Psychology Review*, 18, 199-210.
- Boekaerts, M. i Niemivirta, M. (2005). Self-Regulated Learning: Finding a Balance between Learning Goals and Ego-Protective Goals. U: M. Boekaerts, P.R. Pintrich i M. Zeidner (Ur.), *Handbook of self-regulation*. (str. 417-451). Burlington, MA: Elsevier Academic Press.
- Braš Roth, M., Gregurović, M., Markočić Dekanić, A. i Markuš, M. (2008). *PISA 2006: Prirodoslovne kompetencije za život*. Zagreb: Nacionalni centar za vanjsko vrednovanje obrazovanja – PISA centar.
- Brown, A.L. (1978). Knowing when, where, and how to remember: A problem of metacognition. U: R. Glaser (Ur.), *Advances in instructional psychology, Vol. 1*. (str. 77-165). Hillsdale, NJ: Erlbaum.
- Butler, D. L. (2002). Qualitative approaches to investigating self-regulated learning: Contributions and challenges. *Educational Psychologist*, 37, 59-63.
- Butler, D.L. (1997). *The Roles of Goal Setting and Self-Monitoring in Students' Self-Regulated Engagement in Tasks*. Rad prikazan na godišnjem sastanku American Educational Research Association, Chicago, IL.
- Butler, D.L. (1996). *The Strategic Content Learning Approach to Promoting Self-Regulated Learning: An Introduction to the Coordinated Symposium*. Rad prikazan na godišnjem sastanku American Educational Research Association, New York, NY.
- Butler, D.L. i Cartier, S.C. (2005). *Multiple Complementary Methods for Understanding Self-Regulated Learning as Situated in Context*. Rad prikazan na godišnjem sastanku American Educational Research Association, Montreal, QC.
- Butler, D.L. i Winne, P.H. (1995). Feedback and Self-Regulated Learning: A Theoretical Synthesis. *Review of Educational Research*, 65, 245–281.



- Chen, Z. i Klahr, D. (2008). Remote Transfer of Scientific Reasoning- and Problem-Solving Strategies in Children. U: R.V. Kail (Ur.), *Advances in Child Development and Behavior*, 36 (str. 419-470). Amsterdam: Elsevier.
- Chen, Z. i Klahr, D. (1999). All Other Things Being Equal: Acquisition and Transfer of the Control of Variables Strategy. *Child Development*, 70(5), 1098–1120.
- Chen, Z. i Siegler, R. (2000). III. Microgenetic Methods. *Monographs of the Society for Research in Child Development*, 65(2), 12–16.
- Cheshire, A., Muldoon, K.P., Francis, B., Lewis, C.N., i Ball, L.J. (2007). Modelling change: New opportunities in the analysis of microgenetic data. *Infant and Child Development*, 16, 119-134.
- Chinn, C.A. i Malhorta, B.A. (2002). Epistemologically Authentic Inquiry in Schools: A Theoretical Framework for Evaluating Inquiry Tasks. *Science Education*, 86(2), 175-218.
- Cohen, J. (1992). A power primer. *Psychological Bulletin*, 112(1), 155-159.
- Dean, D. i Kuhn, D. (2006). Direct instruction vs. discovery: The long view. *Science Education*, 91(3), 384-397.
- Dean, D. i Kuhn, D. (2003). Metacognition and Critical Thinking. ERIC document NO. ED 477930.
- De Jong, T. (2006). Computer simulations - Technological advances in inquiry learning. *Science*, 312, 532-533.
- De Jong, T. i Van Joolingen W.R. (1998). Scientific Discovery Learning with Computer Simulations of Conceptual Domains. *Review of Educational Research*, 68, 179-201.
- Dinsmore, D.L., Alexander, P.A. i Loughlin, S.M. (2008). Focusing the Conceptual Lens on Metacognition, Self-regulation, and Self-regulated Learning. *Educational Psychology Review*, 20, 391-409.
- Dunbar, K. i Fugelsang, J. (2005). Scientific Thinking and Reasoning. U: K.J. Holyoak i R.G. Morrison (Ur.), *The Cambridge Handbook of Thinking and Reasoning* (str. 705-726). New York: Cambridge University Press.
- Dunbar, K. i Klahr, D. (1989). Developmental differences in scientific discovery processes. U D.Klahr i K. Kotovsky (Ur.), *Complex information processing: The impact of Herbert A. Simon* (str. 109-143). Hillsdale, NJ: Lawrence Erlbaum Associates.
- Education Council (2006). *Recommendation of the European Parliament and the Council of 18 December 2006 on Key Competencies for Lifelong Learning*. Brussels: Official Journal of the European Union.

- Efklides, A. (2009). The role of metacognitive experiences in the learning process. *Psicothema*, 21(1), 76–82.
- Efklides, A. (2008). Metacognition: Defining Its Facets and Levels of Functioning in Relation to Self-Regulation and Co-regulation. *European Psychologist*, 13(4), 277–287.
- Efklides, A. (2006a). Metacognitive Experience: The Missing Link in the Self-Regulated Learning Process. A rejoinder to Ainley and Patrick. *Educational Psychology Review*, 18, 287–291.
- Efklides, A. (2006b). Metacognition and affect: What can metacognitive experience tell us about the learning process? *Educational Research Review*, 1, 3–14.
- Efklides, A. (2002). The systemic nature of metacognitive experiences: Feelings, judgments, and their interrelations. U M. Izaute, P. Chambres, i P.-J. Marescaux (Ur.), *Metacognition: Process, function, and use* (str. 19-34). Dordrecht, The Netherlands: Kluwer.
- Efklides, A. (2001). Metacognitive Experiences in Problem Solving. U A. Efklides, J. Kuhl i R.M. Sorrentino (Ur.), *Trends and Prospects in Motivation Research* (str. 297-322). Dordrecht: Kluwer Academic Publishers.
- Efklides, A., Kourkoulou, A., Mitsiou, F. i Ziliaskopoulou, D. (2006). Metacognitive knowledge of effort, personality factors, and mood state: their relationships with effort-related metacognitive experience. *Metacognition and Learning*, 1, 33-49.
- Efklides, A. i Petkaki, C. (2005). Effects of mood on students' metacognitive experiences. *Learning and Instruction*, 15, 415-431.
- Ericsson, K.A. i Simon, H.A. (1993). *Protocol Analysis*. Cambridge, MA: MIT Press.
- EURYDICE (2006). *Science teaching in schools in Europe. Policies and research*. Brussel: Eurydice, Directorate-General for Education and Culture.
- Field, A. (2005). *Discovering Statistics Using SPSS* (Second Edition). London, UK: Sage Publications Ltd.
- Field, A. (2000). *Cluster Analysis*. Preuzeto s: <http://www.statisticshell.com/malbowges.html>
- Flavell, J.H. (1979). Metacognition and cognitive monitoring. *American Psychologist*, 34, 906-911.
- Flynn, E., Pine, K.J. i Lewis, C. (2007). Using the Microgenetic Method to Investigate Cognitive Development: An Introduction. *Infant and Child Development*, 16, 1-6.
- Flynn, E., Pine, K. i Lewis, C. (2006). The Microgenetic Method: Time for change? *The Psychologist*, 19(3), 152-155.

- Flynn, E. i Siegler, R. (2007). Measuring Change: Current Trends and Future Directions in Microgenetic Research. *Infant and Child Development*, 16, 135-149.
- Grandy, R. i Duschl, R.A. (2007). Reconsidering the Character and Role of Inquiry in School Science: Analysis of a Conference. *Science & Education*, 16, 141-166.
- Granott, N. i Parziale, J. (2002). Microdevelopment: A process-oriented perspective for studying development and learning. U: N.Granott i J. Parziale (Ur.), *Microdevelopment: Transition Processes in Development and Learning* (str. 1–28). Cambridge: Cambridge University Press.
- Hair, J.F., Black, W.C., Babin, B.J. i Anderson, R.E. (2009). *Multivariate Data Analysis* (7 Ed.). Englewood Cliffs, NJ: Pearson Prentice Hall.
- Hmelo-Silver, C.E., Golan Duncan, R. i Chinn, C.A. (2007). Scaffolding and Achievement in Problem-Based and Inquiry Learning: A Response to Kirschner, Sweller and Clark (2006). *Educational Psychologist*, 42(2), 99–107.
- Holland, J.H., Holyoak, K.J., Nisbett, R.E. i Thagard, P.R. (1986). *Induction: Processes of inference, learning and discovery*. Cambridge: MIT Press.
- Hulshof, C.D. (2001). *Discovery of ideas and ideas about discovery: The influence of prior knowledge on scientific discovery learning in computer-based simulations*. Doktorska disertacija. Twente: University of Twente.
- Hulshof, C.D., Wilhelm, P., Beishuizen, J.J. i van Rijn, H. (2005). FILE: a tool for the study of inquiry learning. *Computers in Human Behavior*, 21, 945–956.
- Inhelder, B. i Piaget, J. (1958). *The Growth of Logical Thinking from Childhood to Adolescence*. New York: Basic Books.
- Järvelä, S. (2001). Shifting Research on Motivation and Cognition to an Integrated Approach on Learning and Motivation in Context. U: S. Volet i S. Järvelä (Ur.), *Motivation in Learning Contexts: Theoretical Advances and Methodological Implications* (str. 3-14). Oxford, UK: Elsevier Science Ltd.
- Järvelä, S., Salonen, P. i Lepola, J. (2002). Dynamic Assessment as a Key to Understanding Student Motivation in a Classroom Context. U: P.R. Pintrich, i M.L. Maehr (Ur.): *New Directions in Measures and Methods. Advances in Motivation and Achievement (Volume 12)* (str. 207–240). Amsterdam: Elsevier Science Ltd.
- Kanari, Z. i Millar, R (2003). Reasoning from data: How students collect and interpret data in science investigations. *Journal of Research in Science Teaching*, 41, 748–769.
- Kaplan, A. (2008). Clarifying Metacognition, Self-Regulation, and Self-Regulated Learning: What's the Purpose? *Educational Psychology Review*, 20, 477-484.
- Keselman, A. (2003). Supporting Inquiry Learning by Promoting Normative Understanding of Multivariable Causality. *Journal of Research in Science Teaching*, 40(9), 89–921.

- Keselman, A. i Kuhn, D. (2002). *Facilitating Self-Directed Experimentation in the Computer Environment*. Preuzeto s: <http://citeseer.ist.psu.edu/509879.html>
- Kirschner, P.A., Sweller, J. i Clark, R.E. (2006). Why Minimal Guidance During Instruction Does Not Work: An Analysis of the Failure of Constructivist, Discovery, Problem-Base, Experiential, and Inquiry-Based Teaching. *Educational Psychologist*, 41(2), 75-86.
- Klahr, D. (2009). To every thing there is a season, and a time to every purpose under the heavens: What about Direct Instruction? U: S. Tobias i T. M. Duffy (Ur.), *Constructivist Theory Applied to Instruction: Success or Failure?* (str. 291-310). New York: Routledge.
- Klahr, D. (2000). *Exploring Science: The Cognition and Development of Discovery Processes*. Cambridge, MA: MIT Press.
- Klahr, D. i Carver, S.M. (1995). Scientific thinking about scientific thinking. *Monographs of the Society for Research in Child Development*, 60, 137–151.
- Klahr, D., Chen, Z. i Toth, E.E. (2001). Cognitive Development and Science Education: Ships that Pass in the Night or Beacons of Mutual Illumination? U: S.M. Carver i D. Klahr (Ur.), *Cognition and Instruction: Twenty-Five Years of Progress* (str. 75-119). Mahwah, New Jersey: LEA Publishers.
- Klahr, D. i Dunbar, K. (1988). Dual space search during scientific reasoning. *Cognitive Science*, 12, 1– 48.
- Klahr, D., Fay, A. i Dunbar, K. (1993). Heuristics for scientific experimentation: A developmental study. *Cognitive Psychology*, 25(1), 111– 146.
- Klahr, D. i Li, J. (2005). Cognitive Research and Elementary Science Instruction: From the Laboratory, to the Classroom, and Back. *Journal of Science Education and Technology*, 14(2), 217-238.
- Klahr, D. i Nigam, M. (2004). The Equivalence of Learning Paths in Early Science Instruction: Effects of Direct Instruction and Discovery Learning. *Psychological Science*, 15(10), 661-667.
- Klahr, D. i Simon, H.A. (2001). What Have Psychologists (And Others) Discovered About the Process of Scientific Discovery? *Current Directions in Psychological Science*, 10(3), 75–79.
- Klahr, D. i Simon, H.A. (1999). Studies of scientific discovery: Complementary approaches and convergent findings. *Psychological Bulletin*, 125(5), 524–543.
- Koslowski, B. (1996). *Theory and Evidence: The Development of Scientific Reasoning*. Cambridge, MA: MIT Press.

- Koslowski, B. i Masnick, A. (2002). The development of causal reasoning. U U. Goswami (Ur.), *Blackwell handbook of childhood cognitive development* (str. 257-281). Malden, MA: Blackwell Publishing Ltd.
- Kuhn, D. (2009). Do students need to be taught how to reason? *Educational Research Review*, 4, 1-6.
- Kuhn, D. (2008). Formal Operations from a Twenty-First Century Perspective. *Human Development*, 51, 48-55.
- Kuhn, D. (2007a). Reasoning About Multiple Variables: Control of Variables Is Not the Only Challenge. *Science Education*, 91(5), 710-726.
- Kuhn, D. (2007b). Is Direct Instruction an Answer to the Right Question? *Educational Psychologist*, 42(2), 109–113.
- Kuhn, D. (2006). The Second Decade: What Develops (and How). U: W. Damon & R. M. Lerner (Ur. Serije) i D. Kuhn i R.S. Siegler (Ur.Vol. 2), *Handbook of Child Psychology, Volume 2: Cognition, perception, and language* (str. 953-993). Hoboken, NY: John Wiley & Sons Inc.
- Kuhn, D. (2005). *Education for Thinking*. Cambridge, MA: Harvard University Press.
- Kuhn, D. (2002a). What is Scientific Thinking and How Does It Develop. U: U. Goswami, (Ur.), *Blackwell Handbook of Childhood Cognitive Development* (str. 371-393). Malden, MA: Blackwell Publishing Ltd.
- Kuhn, D. (2002b). A multi-component system that constructs knowledge: insights from microgenetic study. U: N. Granott, i J. Parziale, (Ur.), *Microdevelopment: Transition Processes in Development and Learning* (str.109-130). Cambridge: Cambridge University Press.
- Kuhn, D. (2001a). How do people know? *Psychological Science*, 12(1), 1-8.
- Kuhn, D. (2001b). Why Development Does (and Does Not) Occur: Evidence from the Domain of Inductive Reasoning. U: J.L. McClelland, i R.S. Siegler, (Ur.), *Mechanisms of Cognitive Development: Behavioral and Neural Perspectives* (str.221-249). Mahwah, NJ: Lawrence Erlbaum Associates, Inc. Publishers.
- Kuhn, D. (2000). Metacognitive Development. *Current Directions in Psychological Science*, 9(5), 178–181.
- Kuhn, D. (1999). Metacognitive Development. U: L.Balter i C.Tamis-LeMonda (Ur.), *Child Psychology: Handbook of Contemporary Issues* (str. 259-286). Philadelphia: Psychology Press.
- Kuhn, D. (1997). Constraints or Guideposts? Developmental Psychology and Science Education. *Review of Educational Research*, 67(1), 141–150.

- Kuhn, D. (1995). Microgenetic Study of Change: What Has It Told Us? *Psychological Science*, 6(3), 133–139.
- Kuhn, D. (1989). Children and Adults as Intuitive Scientists. *Psychological Review*, 96(4), 674–689.
- Kuhn, D., Amsel, E. i O’Loughlin, M. (1988). *The Development of Scientific Thinking Skills*. Developmental Psychology Series. San Diego, CA: Academic Press, Inc.
- Kuhn, D, Black J., Keselman, A. i Kaplan, D. (2000). The Development of Cognitive Skills To Support Inquiry Learning. *Cognition and Instruction*, 18(4), 495–523.
- Kuhn, D., Cheney, R. i Weinstock, M. (2000). The development of epistemological understanding. *Cognitive Development*, 15, 309-328.
- Kuhn, D. i Dean, D. (2008). Scaffolded Development of Inquiry Skills in Academically Disadvantaged Middle-School Students. *Journal of Psychology of Science and Technology*, 1(2), 36-50.
- Kuhn, D. i Dean, D. (2005). Is Developing Scientific Thinking All About Learning to Control Variables. *Psychological Science*, 16(11), 866–870.
- Kuhn, D. i Dean, D. (2004a). Connecting Scientific Reasoning and Causal Inference. *Journal of Cognition and Development*, 5(2), 261–288.
- Kuhn, D. i Dean, D. (2004b). Metacognition: A bridge Between Cognitive Psychology and Educational Practice. *Theory into Practice*, 43(4), 268-273.
- Kuhn, D. i Franklin, S. (2006). The Second Decade: What Develops (and How). U: W. Damon & R. M. Lerner (Ur. Serije) i D. Kuhn i R.S. Siegler (Ur.Vol. 2), *Handbook of Child Psychology, Volume 2: Cognition, perception, and language* (str. 953-993). Hoboken, NY: John Wiley & Sons Inc.
- Kuhn, D., Garcia-Milà, M., Zohar, A. i Andersen, C. (1995). Strategies of Knowledge Acquisition. *Monographs of the Society for Research in Child Development*, 60, 1-128.
- Kuhn, D., Iordanou, K., Pease, M. i Wirkala, C. (2008). Beyond control of variables: What needs to develop to achieve skilled scientific thinking? *Cognitive Development*, 23(4), 435-451.
- Kuhn, D., Katz, J.B. i Dean, D. (2004). Developing Reason. *Thinking & Reasoning*, 10(2), 197-219.
- Kuhn, D. i Park, S-H. (2005). Epistemological Understanding and the Development of Intellectual Values. *International Journal of Educational Research*, 43(3), 111-124.
- Kuhn, D. i Pearsall, S. (2000). Developmental Origins of Scientific Thinking. *Journal of Cognition and Development*, 1, 113–129.

- Kuhn, D. i Pearsall, S. (1998). Relations between Metastrategic Knowledge and Strategic Performance. *Cognitive Development*, 13, 227–247.
- Kuhn, D. i Pease, M. (2010). The Dual Components of Developing Strategy Use: Production and Inhibition. U: H. Salatas Waters i J.G. Borkowski, *Metacognition, Strategy Use & Instruction* (str. 135-159). New York: The Guilford Press.
- Kuhn, D. i Pease, M. (2008). What Needs to Develop in the Development of Inquiry Skills? *Cognition and Instruction*, 26(4), 512–559.
- Kuhn, D., Pease, M. i Wirkala, C. (2009). Coordinating the effects of multiple variables: A skill fundamental to scientific thinking. *Journal of Experimental Child Psychology* 103, 268-284.
- Kuhn, D. i Phelps, E. (1982). The development of problem-solving strategies. U: H.Reese (ur.), *Advances in Child Development and Behavior*, Vol. 17 (str. 1-44), New York: Academic Press.
- Kuhn, D., Schauble, L. i Garcia-Mila, M. (1992). Cross-Domain Development of Scientific Reasoning. *Cognition and Instruction*, 9(4), 285–327.
- Lajoie, S.P. (2008). Metacognition, Self Regulation, and Self-regulated Learning: A Rose by any other Name? *Educational Psychology Review*, 20, 469-475.
- Landis, J.R. i Koch, G.G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159-174.
- Lavelli, M., Pantoja A.P.F., Hsu, H., Messinger, D. i Fogel, A. (2005). Using Microgenetic Designs to Study Change Processes. U: D.G. Teti (Ur.), *Handbook of Research Methods in Developmental Psychology* (str. 40-63). Malden: Blackwell Publishers.
- Lehrer, R. i Schauble, L. (2006). Scientific Thinking and Science Literacy: Supporting Development in Learning Context. U: W. Damon i R. Lerner (Ur.serije), K.A Renniger. i I.E. Sigel, (Ur.), *Handbook of Child psychology: Vol.4. Child Psychology in practice* (str.153-196). New York: Wiley and Sons.
- Li, J. i Klahr, D. (2006). The Psychology of Scientific Thinking: Implications for Science Teaching and Learning. U: J. Rhoton, i P. Shane, (Ur.): *Teaching Science in the 21<sup>st</sup> Century* (str. 307-325). National Science Teachers Association and National Science Education Leadership Association, NSTA Press.
- Lin, X. i Lehman, J.D. (1999). Supporting learning of variable control in a computer-based biology environment: Effects of prompting college students to reflect on their own thinking. *Journal of Research in Science Teaching*, 36, 837-858.
- Loyens, S. M.M., Magda, J. i Rikers, R.M.J.P. (2008). Self-Directed Learning in Problem-Based Learning and its Relationships with Self-Regulated Learning. *Educational Psychology Review*, 20, 411-427.

- MacLeod, W.B., Butler, D.L. i Syer, K.D. (1996). *Beyond Achievement Data: Assessing Changes in Metacognition and Strategic Learning*. Rad prikazan na godišnjem sastanku American Educational Research Association, New York, NY.
- Meijer, J., Veenman, M.V.J. i Van Hout-Wolters, B.H.A.M. (2006). Metacognitive Activities in Text-Studying and Problem-Solving: Development of a taxonomy. *Educational Research and Evaluation*, 12(3), 209-237.
- Metallidou, P. i Efklides, A. (2001). The effects of general success-related beliefs and specific metacognitive experiences on causal attributions. U A. Efklides, J. Kuhl i R.M. Sorrentino (Ur.), *Trends and Prospects in Motivation Research* (str. 325-348). Dordrecht: Kluwer Academic Publishers.
- Ministarstvo znanosti, obrazovanja i športa (2006). *Nastavni plan i program za osnovnu školu*. Zagreb: Ministarstvo znanosti, obrazovanja i športa.
- Murphy, C. (2003). *Literature Review in Primary Science and ICT*. Bristol, UK: Futurelab report 5.
- National Research Council (2000). *Inquiry and the national science education standards: A guide for teaching and learning*. Washington, DC: National Academy Press.
- Nelson, T.O. (1996). Consciousness and metacognition. *American Psychologist*, 51, 102–116.
- Niemivirta, M. (2006). Assessing Motivation and Self-Regulation in Learning within a Predictive Design: Incorporating Systematic Elements of Change. *Educational Psychology Review*, 18, 255-259.
- Niemivirta, M. (2002). Individual Differences and Developmental Trends in Motivation: Integrating Person-Centred and Variable-Centred Methods. U: P.R. Pintrich i M.L. Maehr (Ur.), *New Directions in Measures and Methods. Advances in Motivation and Achievement (Volume 12)* (str. 241-275). Amsterdam: Elsevier Science Ltd.
- Niemivirta, M. i Tapola, A. (2007). Self-Efficacy, Interest, and Task Performance: Within-task Changes, Mutual Relationships, and Predictive Effects. *Zeitschrift für Pädagogische Psychologie*, 21(3/4), 241-250.
- Nolen, S.B. (2006). Validity in Assessing Self-Regulated Learning: A comment on Perry & Wine. *Educational Psychology Review*, 18, 229–232.
- OECD (Organisation for economic co-operation and development) (2006). *Assessing Scientific, Reading and Mathematical Literacy: A Framework for PISA 2006*. Paris: OECD.
- Osborne, J. i Dillon, J. (2008). *Science Education in Europe: Critical Reflections*. A report to the Nuffield Foundation. Preuzeto s:  
[www.nuffieldfoundation.org/.../Sci\\_Ed\\_in\\_Europe\\_Report\\_Final.pdf](http://www.nuffieldfoundation.org/.../Sci_Ed_in_Europe_Report_Final.pdf)



- Osborne, J. i Hennessy, S. (2006). *Literature Review in Science Education and the Role of ICT: Promise, Problems and Future Directions*. Bristol, UK: Futurelab report 6.
- Patrick, H. i Middleton, M.J. (2002). Turning the Kaleidoscope: What We See When Self-Regulated Learning is Viewed With Qualitative Lens. *Educational Psychologist*, 37(1), 27–39.
- Patton, M.Q. (1990). *Qualitative evaluation and research methods*. Beverly Hills, CA: Sage.
- Pearsall, S. (1999). *The influence of metacognitive reflection on the development of scientific reasoning*. Neobjavljena doktorska disertacija. New York: Teachers College, Columbia University.
- Perry, N.E. i Winne, P.H. (2006). Learning from Learning Kits: gStudy Traces of Students' Self-Regulated Engagements with Computerized Content. *Educational Psychology Review*, 18, 211-228.
- Pintrich, P.R. (2005). The Role of Goal Orientation in Self-Regulated Learning. U: M. Boekaerts, P.R. Pintrich i M. Zeidner (Ur.), *Handbook of self-regulation*. (str. 417-451). Burlington, MA: Elsevier Academic Press.
- Pintrich, P.R. (2004). A Conceptual Framework for Assessing Motivation and Self-Regulated Learning in College Students. *Educational Psychology Review*, 16(4), 385–407.
- Pintrich, P.R. (2003). A Motivational Science Perspective on the Role of Student Motivation in Learning and Teaching Contexts. *Journal of Educational Psychology*, 95(4), 667 – 686.
- Pintrich, P.R. (2002). The Role of Metacognitive Knowledge in Learning, Teaching, and Assessing. *Theory into Practice* 41(4), 219-225.
- Pintrich, P.R. (1999). The Role of Motivation in Promoting and Sustaining Self-Regulated Learning. *International Journal of Educational Research*, 31, 459–470.
- Pogačnik, V. (1997). *Priručnik za Test nizova*. Jastrebarsko: Naklada Slap.
- Prins, F.J. (2002). *The Roles of Metacognitive Skillfulness and Intellectual Ability During Novice Inductive Learning in a Complex Computer-Simulated Environment*. Doktorska disertacija. Leiden: Universiteit Leiden.
- Prins, F.J., Veenman, M.V.J. i Elshout, J.J. (2006). The impact of intellectual ability and metacognition on learning: New support for the threshold of problematicity theory. *Learning and Instruction*, 16, 374-387.
- Puustinen, M. i Pulkkinen, L. (2001). Models of Self-regulated Learning: a review. *Scandinavian Journal of Educational Research*, 45(3), 269–286.

- Rheinberg, F., Vollmeyer, R. i Burns, B.D. (2000). Motivation and Self-Regulated Learning. U J. Heckhausen (Ur.), *Motivational Psychology of Human Development: Developing Motivation and Motivating Development* (str. 81-108). Amsterdam, The Netherlands: Elsevier Science B.V.
- Rheinberg, F., Vollmeyer, R. i Rollett, W. (2005). Motivation and Action in Self-Regulated Learning. U: M. Boekaerts, P.R. Pintrich i M. Zeidner (Ur.), *Handbook of self-regulation*. (str. 417-451). Burlington, MA: Elsevier Academic Press.
- Rheinberg, F., Vollmeyer, R. i Rollett, W. (2002). Motivation and Self-Regulated Learning: A Type Analysis with Process Variables. *Psychologia*, 45, 237-249.
- Rocard, M., Csermely, P., Jorde, D., Lenzen, D., Walberg-Henriksson, H. i Hemmo, V. (2007). *Science Education NOW: A Renewed Pedagogy for the Future of Europe*. Brussels: European Commission, Directorate-General for Research Science, Economy and Society.
- Sansone, C. i Thoman, D.B. (2005). Does what we feel affect what we learn? Some answers and new questions. *Learning and Instruction*, 15, 507-515.
- Schauble, L. (1996). The Development of Scientific Reasoning in Knowledge-Rich Contexts. *Developmental Psychology*, 32(1), 102–119.
- Schauble, L. (1990). Belief revision in children: The role of prior knowledge and strategies for generating evidence. *Journal of Experimental Child Psychology*, 49, 31-57.
- Schauble, L., Klopfer, L.E. i Raghavan, K. (1991). Students' transition from an engineering model to a science model of experimentation. *Journal of Research in Science Teaching*, 28, 859-882.
- Schraw, G. (2007). The use of computer-based environments for understanding and improving self-regulation. *Metacognition and Learning*, 2, 169–176.
- Schraw, G. (2002). Promoting General Metacognitive Awareness. U: H.J. Hartman (Ur.), *Metacognition in Learning and Instruction* (str. 3-16). Dordrecht, The Netherlands: Kluwer Academic Publishers.
- Schunk, D.H. (2008). Metacognition, Self-Regulation, and Self-Regulated Learning: Research Recommendations. *Educational Psychology Review*, 20, 463-467.
- Schunk, D.H. i Zimmerman, B.J. (Ur.) (1998). *Self-regulated learning: From Teaching to Self-Reflective Practice*. New York: The Guilford Press.
- Siegler, R.S. (2007). Cognitive Variability. *Developmental Science*, 10(1), 104-109.
- Siegler, R.S. (2006). Microgenetic Analysis of Learning. U: W. Damon & R. M. Lerner (Ur. Serije) i D. Kuhn i R.S. Siegler (Ur. Vol. 2), *Handbook of Child Psychology, Volume 2: Cognition, perception, and language* (str. 464-510). Hoboken, NY: John Wiley & Sons Inc.

- Siegler, R.S. (2000). The Rebirth of Children's Learning. *Child Development*, 71(1), 26–35.
- Siegler, R. S. i Crowley, K. (1991). The Microgenetic Method: A Direct Means for Studying Cognitive Development. *American Psychologist*, 46(6), 606–620.
- Siegler, R. i Jenkins, E. (1989). *How Children Discover New Strategies*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- Siegler, R.S. i Shipley, C. (1995). Variation, Selection, and Cognitive Change. U: T. Simon i G. Halford (Ur.), *Developing cognitive competence: New approaches to process modeling*. Hillsdale, NJ: Erlbaum.
- Sodian, B. i Bullock, M. (2008). Scientific reasoning – Where are we now? *Cognitive Development*, 23(4), 431-434.
- Sodian, B., Zaitchik, D. i Carey, S. (1991). Young children's differentiation of hypothetical beliefs from evidence. *Child Development*, 62, 753-766.
- Sperling, R.A., Howard, B.C i Staley, R. (2004). Metacognition and Self-Regulated Learning Constructs. *Educational Research and Evaluation*, 10(2), 117–139.
- Stake, R. (1995). *The art of case research*. Thousand Oaks, CA: Sage Publications.
- Strand-Cary, M. i Klahr, D. (2008). Developing elementary science skills: Instructional effectiveness and path independence. *Cognitive Development*, 23, 488–511.
- Tschirgi, J.E. (1980). Sensible Reasoning: a hypothesis about hypotheses. *Child Development*, 51, 1-10.
- Turner J.C. (2006). Measuring Self-Regulation: A Focus on Activity. *Educational Psychology Review*, 18, 293–296.
- Turner, J.C. (2001). Using Context to Enrich and Challenge our Understanding of Motivational Theory. U: S. Volet i S. Järvelä (Ur.), *Motivation in Learning Contexts: Theoretical Advances and Methodological Implications* (str. 85-104). Oxford, UK: Elsevier Science Ltd.
- Van der Stel, M. i Veenman, M.V.J. (2008). Relation between intellectual ability and metacognitive skillfulness as predictors of learning performance of young students performing tasks in different domains. *Learning and Individual Differences*, 18, 128-134.
- Van Joolingen, W.R., de Jong, T. i Dimitrakopoulou, A. (2007). Issues in computer supported inquiry learning in science. *Journal of Computer Assisted Learning*, 23(2), 111-119.
- Van Rijn, H. (1999). *FILE Resources*. Preuzeto s: <http://www.swi.psy.uva.nl/projects/il/file>

- Veenman, M.V.J. (2007). The assessment and instruction of self-regulation in computer-based environments: a discussion. *Metacognition and Learning*, 2, 177–183.
- Veenman, M. V. J., Elshout, J. J. i Meijer, J. (1997). The generality vs domain-specificity of metacognitive skills in novice learning across domains. *Learning and Instruction*, 7(2), 187-209.
- Veenman, M.V.J., Prins, F.J. i Elshout, J.J. (2002). Initial inductive learning in a complex computer simulated environment: the role of metacognitive skills and intellectual ability. *Computers in Human Behaviour*, 18, 327–341.
- Veenman, M.V.J. i Spaans, M.A. (2005). Relation between intellectual and metacognitive skills: Age and task differences. *Learning and Individual Differences*, 15, 159-176.
- Veenman, M.V.J., van Hout-Wolters, B.H.A.M, Afflerbach, P. (2006). Metacognition and learning: conceptual and methodological considerations. *Metacognition and Learning*, 1, 3–14.
- Veenman, M.V.J., Wilhelm, P. i Beishuizen, J.J. (2004). The relation between intellectual and metacognitive skills from a developmental perspective. *Learning and Instruction*, 14, 89–109.
- Vollmeyer, R. i Rheinberg, F. (2006). Motivational Effects on Sel-Regulated Learning with Different Tasks. *Educational Psychology Review*, 18, 239-253.
- Vollmeyer, R. i Rheinberg, F. (2005). A surprising effect of feedback on learning. *Learning and Instruction*, 15, 589-602.
- Vollmeyer, R. i Rheinberg, F. (2000). Does motivation affect performance via persistence? *Learning and Instruction*, 10, 293-309.
- Vollmeyer, R. i Rheinberg, F. (1999). Motivation and metacognition when learning a complex system. *European Journal of Psychology of Education*, 16(4), 541-554.
- Vollmeyer, R., Rollett, W. i Rheinberg, F. (1997). How Motivation Affect Learning. U: M.G. Shafto i P.Langley (Ur.), *Proceedings of the nineteenth annual conference of the cognitive science society* (str. 796-801). Mahwah, NJ: Erlbaum.
- Wilhelm, P. i Beishuizen, J.J. (2004). Asking Questions During Self-Directed Inductive Learning: Effects on Learning Outcome and Learning Processes. *Interactive Learning Environments*, 12(3), 251–264.
- Wilhelm, P. i Beishuizen, J.J. (2003). Content effects in self-directed inductive learning. *Learning and Instruction*, 13, 381-402.
- Wilhelm, P., Beishuizen, J.J. i van Rijn, H. (2005). Studying inquiry learning with FILE. *Computers in Human Behavior*, 21, 933-943.
- Winne, P.H (1996). A metacognitive view of individual differences in self-regulated learning. *Learning and Individual Differences*, 8, 327–353.

- Winne, P.H. (1995). Inherent details in self-regulated learning. *Educational Psychologist*, 30, 173–187.
- Winne, P.H. i Hadwin, A.F. (1998). Studying as self-regulated learning. U: D.J. Hacker, J.Dunlosky i A.C. Graesser (Ur.), *Metacognition in educational theory and practice* (str. 279-306). Hillsdale, NJ: Erlbaum.
- Winne, P.H., Jamieson-Noel, D. i Muis, K.R. (2002). Methodological Issues and Advances in Researching Tactics, Strategies, and Self-Regulated Learning. U: P.R. Pintrich, i M.L. Maehr (Ur.): *New Directions in Measures and Methods. Advances in Motivation and Achievement (Volume 12)* (str. 121-155). Amsterdam: Elsevier Science Ltd.
- Winne, P.H i Perry N.E. (2005). Measuring Self-Regulated Learning. U: M. Boekaerts, P. R. Pintrich, i M. Zeidner (Ur.), *Handbook of self-regulation* (str. 531-566). Burlington, MA : Elsevier Academic Press.
- Winters, F.I., Greene, J.A. i Costich, C.M. (2008). Self-Regulation of Learning within Computer-based Learning Environments: A Critical Analysis. *Educational Psychology Review*, 20, 429-444.
- Wolters, C.A. (2003). Regulation of Motivation: Evaluating an Underemphasized Aspect of Self-Regulated Learning. *Educational Psychologist*, 38(4), 189–205.
- Wolters, C.A., Pintrich, P.R. i Karabenick, S.A. (2003). *Assessing Academic Self-regulated Learning*. Rad prikazan na Conference on Indicators of Positive Development: Definitions, Measures, and Prospective Validity, Washington, DC.
- Yin, R.K. (1994). *Case Study Research: Design and Methods*. Thousand Oaks: Sage.
- Zeidner, M., Boekaerts, M., Pintrich, P.R. (2005). Self-Regulation: Directions and Challenges for Future Research. U: M. Boekaerts, P.R. Pintrich i M. Zeidner (Ur.), *Handbook of self-regulation*. (str. 417-451). Burlington, MA: Elsevier Academic Press.
- Zimmerman, B.J. (2005). Attaining Self-Regulation: a Social Cognitive Perspective. U , M. Boekaerts, P.R. Pintrich i M. Zeidner (Ur.), *Handbook of self-regulation* (str. 13-35). Burlington, MA: Elsevier Academic Press.
- Zimmerman, B.J. (1990). Self-Regulated Learning and Academic Achievement: An Overview. *Educational Psychologist*, 25(1), 3–17.
- Zimmerman, B.J. i Schunk, D.H. (Ur.) (1989). *Self-Regulated Learning and Academic Achievement: Theory, Research and Practice*. New York: Springer Verlag.
- Zimmerman, C. (2007). The development of scientific thinking skills in elementary and middle school. *Developmental Review*, 27, 172–223.

- Zimmerman, C. (2005). *The Development of Scientific Reasoning Skills: What Psychologists Contribute to an Understanding of Elementary Science Learning*. (Final draft of a Report to the National Research Council Committee on Science Learning Kindergarten through Eighth Grade). Washington, DC: National Research Council.
- Zimmerman, C. (2000). The Development of Scientific Reasoning Skills. *Developmental Review*, 20, 99–149.
- Zohar, A. (1995). Reasoning about Interactions between Variables. *Journal of Research in Science Teaching*, 32(10), 1039-1063.
- Zohar, A. i Ben David, A. (2008). Explicit teaching of meta-strategic knowledge in authentic classroom situations. *Metacognition and Learning*, 3, 59-82.
- Zohar, A. i Peled, B. (2008). The effects of explicit teaching of metastrategic knowledge on low- and high-achieving students. *Learning and Instruction*, 18, 337-353.

## SAŽETAK I KLJUČNE RIJEČI

---

U radu je istraživačko učenje smješteno u okvir integrativnog pristupa istraživanju znanstvenog razmišljanja, koji učenike stavlja u situacije učenja koje od njih zahtijevaju sudjelovanje u svim fazama istraživačkog procesa (od postavljanja hipoteza, preko eksperimentiranja, vrednovanja nalaza i kauzalnog zaključivanja, do revidiranja početnih teorija).

Istraživačko učenje je definirano kao proces (događaj), koji se odvija u stvarnom vremenu u okvirima specifičnih situacija učenja na jednom zadatku. Ovo učenje je konceptualizirano kao samoregulirajuće učenje u kojem sudjeluju i međusobno djeluju različiti kognitivni, metakognitivni, motivacijski i emocionalni procesi.

Dosadašnja istraživanja uglavnom nisu tretirala istraživačko učenje u njegovoj cjelovitosti, već su se usmjeravala na izučavanje pojedinih kognitivnih i metakognitivnih procesa. Cilj je ovog istraživanja sveobuhvatno istražiti promjene u različitim kognitivnim, metakognitivnim i motivacijskim procesima istraživačkog učenja do kojih dolazi uslijed ponavljanih izlaganja učenika situacijama učenja. Osim toga, istraživanje za cilj ima ispitati ulogu metakognitivnih i motivacijskih procesa u korištenju istraživačkih pristupa i stjecanju znanja.

U istraživanju je korišten mikrorazvojni istraživački pristup. Sudjelovalo je 34 učenika osmih razreda koji su samostalno radili na jednom zadatku istraživačkog učenja u računalnom okruženju programa FILE (Flexible Inquiry Learning Environment, Hulshof i sur., 2005). U zadatku se od učenika zahtijeva osmišljavanje i provođenje eksperimenata na temelju kojih se zaključuje o kauzalnoj strukturi multivarijatnog modela zadatka (o odnosima između pet nezavisnih i jedne zavisne varijable). U cilju praćenja promjena u stjecanju znanja i korištenju istraživačkih vještina i strategija, učenici su sudjelovali u četiri situacije učenja u razmacima od oko tjedan dana.

Rezultati istraživanja pokazuju da učenici, iako ne ostvaruju potpuno znanje i potpuno valjano eksperimentiranje i zaključivanje, tijekom rada na zadatku napreduju u korištenju istraživačkih i metakognitivnih vještina i strategija, u stjecanju znanja o području i stjecanju metakognitivnih znanja o cilju i strategijama rada na zadatku. Na temelju kvantitativnih analiza skupnih rezultata i kvalitativnih studija slučajeva, istraživanje također ukazuje da je korištenje metakognitivnih znanja i vještina ključna odrednica uspješnog istraživačkog učenja, te sugerira da motivacija za rad na zadatku može pospješiti ili ograničiti istraživačko učenje djelovanjem na vrijeme učenja i odabir istraživačkog pristupa. Osim za daljnja istraživanja u području istraživačkog učenja, dobiveni rezultati imaju jasne praktične implikacije za osmišljavanje modela i postupaka poučavanja i učenja znanstvenog razmišljanja u okviru osnovnoškolskog obrazovanja.

### **Ključne riječi:**

istraživačko učenje, znanstveno razmišljanje, eksperimentiranje, kauzalno zaključivanje, metakognitivno znanje, metakognitivne vještine, metakognitivni doživljaj, motivacija, samoregulirajuće učenje, mikrorazvojni istraživački pristup

## SUMMARY AND KEY WORDS

---

This study on inquiry learning has taken an integrated approach for investigating scientific reasoning, in which participants take part in all phases of the scientific discovery process (from hypothesis generation, through experimentation, evidence evaluation and causal reasoning, to the revision of initial theories).

Inquiry learning has been defined as a process (or event) that takes place in real time within specific learning situations on a particular task. In addition, such learning has been conceptualised as self-regulated learning, in which various cognitive, metacognitive, motivational and emotional processes interact.

Thus far, research endeavours have failed to capture inquiry learning in its entirety, instead focusing on examining particular cognitive and metacognitive processes in isolation. As such, the aim of the present research is to holistically investigate the changes in various cognitive, metacognitive and motivational processes involved in inquiry learning that occur as a result of repeated exposure of pupils to learning situations. Furthermore, the research aims to investigate the role of metacognitive and motivational processes in the selection and application of investigative approaches and the acquisition of domain knowledge.

The present research employed a microgenetic approach. The participants were 34 8<sup>th</sup> grade pupils, who participated in a self-directed experimentation task in a computer-supported environment using the FILE programme (Flexible Inquiry Learning Environment, Hulshof i sur., 2005). The task required pupils to design and conduct experiments and to make inferences regarding the causal structure of a multivariable causal system (relationships between five independent variables and one dependent variable). In order to track changes in the processes of knowledge acquisition and the application of investigative skills and strategies, pupils participated in four learning sessions over the course of one month.

The results indicate that, although absolute levels of knowledge and completely valid experimentation and inference skills were not reached, pupils demonstrated improvement in their use of investigative and metacognitive skills and strategies, and acquired domain knowledge, as well as metatask and metastrategic knowledge. Results stemming from the triangulation of the quantitative analyses of group data and qualitative case studies also suggest that the use of metacognitive knowledge and skills represents a critical component for successful inquiry learning. These analyses also indicate that pupils' situation specific motivation can facilitate or limit inquiry learning by affecting the time spent on learning and pupils' selection of inquiry approach.

In addition to holding several implications for future research in the field of inquiry learning, the results offer clear practical implications for the conceptualisation of models and practices for learning and teaching scientific reasoning skills in elementary education.

### **Key words:**

Inquiry learning, scientific thinking, experimentation, causal reasoning, metacognitive knowledge, metacognitive skills, metacognitive experience, motivation, self-regulated learning, microgenetic research



## ŽIVOTOPIS

---

Rođena sam 15. ožujka 1974. godine u Varaždinu. Petu gimnaziju u Zagrebu završila sam 1992. godine. Iste godine upisala sam studij psihologije na Odsjeku za psihologiju Filozofskog fakulteta Sveučilišta u Zagrebu, na kojem sam diplomirala 1997. godine s temom iz ekološke psihologije. Od 1998. do 2003. godine radila sam u agencijama za istraživanje tržišta i javnog mnijenja. Od 2003. godine do danas zaposlena sam kao asistentica na Institutu za društvena istraživanja u Zagrebu, u Centru za istraživanje i razvoj obrazovanja. Sudjelovala sam na nizu znanstveno-istraživačkih i razvojnih projekata, od kojih bih istaknula „Samovrednovanje škola u funkciji unapređivanja kvalitete obrazovanja“, „Uvođenje nacionalnih ispita i državne mature u hrvatski školski sustav“, „Praćenje pojave privatnih instrukcija u hrvatskom obrazovnom sustavu“ i „Ispitivanje ključne kompetencije 'učiti kako učiti' u osnovnom školstvu Republike Hrvatske“. Trenutno sudjelujem na projektima „Ujednačavanje i podizanje kvalitete hrvatskog osnovnoškolskog obrazovanja“, „Razvoj modela regulacije pojave privatnih instrukcija“ i „Analiza konstruktne valjanosti i metrijskih karakteristika ispitnih materijala NCVVO-a iz prirodoslovnog područja“. Do sada sam u koautorstvu objavila jednu znanstvenu knjigu, četiri poglavlja u knjigama, sedam znanstvenih radova, te više stručnih članaka, elaborata i izvješća. Sudjelovala sam na više međunarodnih i domaćih znanstvenih i stručnih skupova. Članica sam Hrvatske psihološke komore, Europskog udruženja za istraživanje učenja i poučavanja (*European Association for Research on Learning and Instruction* EARLI) i Europskog udruženja za istraživanje znanstvenog obrazovanja (*European Science Education Research Association* ESERA).

Zrinka Ristić Dedić

rujan 2010.

## PRILOZI

---

- I. Upitnik iz predispozicija
- II. Upute za rad na zadatku
- III. Opis točnog rješenja zadatka, cilja zadatka i primjer valjanog pristupa eksperimentiranju
- IV. Zahvalnice ispitanicima za sudjelovanje u istraživanju
- V. Tablice
- VI. Rezultati hijerarhijske klaster analize učenika na temelju doživljaja zadatka
- VII. Popis svih eksperimenata slučajeva (učenika) obuhvaćenih kvalitativnom analizom procesa učenja