Odnos različitih vidova brzine obrade podataka s fluidnom inteligencijom i velepetorim osobinama ličnosti u mlađoj odrasloj dobi

Lozo, Borna

Master's thesis / Diplomski rad

2019

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:111:878765

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

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

Repository / Repozitorij:

Repository of University of Zagreb, Centre for Croatian Studies

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI

Borna Lozo

Odnos različitih vidova brzine obrade podataka s fluidnom inteligencijom i velepetorim osobinama ličnosti u mlađoj odrasloj dobi

DIPLOMSKI RAD

Zagreb, 2019.

SVEUČILIŠTE U ZAGREBU
HRVATSKI STUDIJI
ODSJEK ZA PSIHOLOGIJU

Borna Lozo

Odnos različitih vidova brzine obrade podataka s fluidnom inteligencijom i velepetorim osobinama ličnosti u mlađoj odrasloj dobi

DIPLOMSKI RAD

Mentor: doc.dr.sc. Mislav Stjepan Žebec

Zagreb, 2019.

Odnos različitih vidova brzine obrade podataka s fluidnom inteligencijom i velepetorim osobinama ličnosti u mlađoj odrasloj dobi

Sažetak

Brzina obrade podatka (BOP) je bitan konstrukt u različitim psihologijskim teorijama, npr., javlja se kao sastavnica fluidne inteligencije i u modelima odnosa ličnosti i inteligencije. Istraživanja BOP-a najčešće ga prikazuju putem prosječnog pokazatelja, iako modeli s neprosječnim pokazateljima imaju inkrementalnu valjanost i teoretski bolje opisuju dinamički model BOP-a. Stoga je cilj ovog rada bio istražiti osjetljivost i valjanost pokazatelja prosječne djelotvornosti, ali i novouvedenih neprosječnih indikatora: nestabilnosti i otpornosti djelovanju nepovoljnih utjecaja. Analiziran je njihov odnos s mjerom fluidne inteligencije i relevantnim dimenzijama ličnosti radi sveobuhvatnijeg sagledavanja teorijskog modela i uloge BOP-a. Uzorak je činilo 209 studenata Fakulteta prometnih znanosti i Hrvatskih studija Sveučilišta u Zagrebu. BOP je mjeren testom KS2-2, fluidna inteligencija je procijenjena testom D-2000, a osobine ličnosti upitnikom IPIP 50. Podaci su prikupljeni papir-olovka instrumentima u standardiziranim uvjetima. Stabilnost nalaza u dva ispitana uzorka opravdala su spajanje uzoraka, ali i ukazala na valjanost korištene metodologije i mjernih instrumenata. Dobra psihometrijska svojstva pokazatelja, od kojih su dva bila značajni prediktori fluidne inteligencije, potvrdila su valjanost korištenog modela BOP-a, posebice opravdanost korištenja neprosječnih pokazatelja, iako su mjere nestabilnosti i otpornosti imale stanovita ograničenja osjetljivosti. Svi indikatori BOP-a povezani su s mjerom fluidne inteligencije i tek djelomično s relevantnim osobinama ličnosti. Dobivene povezanosti najvećim su dijelom usklađene s teorijskim očekivanjima, čak i iznad tih očekivanja, kad se u obzir uzmu neke nepovoljne psihometrijske osobine ne-prosječnih varijabli BOP-a.

Ključne riječi: brzina obrade podatka, pokazatelji dinamike funkcioniranja brzine obrade podataka, fluidna inteligencija, velepetore osobine ličnosti

The Relationship of Different Aspects of Information Processing Rate with Fluid Intelligence and the Big Five Personality Traits in Young Adulthood

Abstract

Information processing rate (IPR) is an important construct within many psychological theories, e.g., as a component of fluid intelligence and within models that explain links between personality and intelligence. IPR research usually describes it by using average indicators, even though models with non-average indicators have incremental validity and theoretically better describe the proposed dynamic model of IPR. Accordingly, the objective of this paper was to investigate the psychometric sensitivity and validity of indicators of average efficiency and newly introduced indicators of instability and resilience to adverse influences. Their relationships with a measure of fluid intelligence and with relevant Big Five personality traits were analyzed in order to more comprehensively examine the theoretical model and role of IPR. The sample was comprised of 209 students of Faculty of Transportation Sciences and of Croatian Studies University of Zagreb. IPR was measured by the KS2-2 test, fluid intelligence

by the D-2000 test and the Big Five personality traits by the IPIP 50 questionnaire. Data was collected by paper-and-pencil instruments in standardized conditions. The consistency of the two samples' results justified their joining and indicated that the studies methodology and instruments where valid. Good psychometric properties of IPR indicators, two of which acted as signifficant predictors of fluid intelligence, confirmed the validity of the assessed IPR model, especially the justifiability of the non-average IPR indicators use, even though indicators of instability and resilience exhibited certain sensitivity constraints. All IPR indicators significantly correlated with fluid intelligence and only partially correlated with relevant personality traits. The obtained correlation mostly corroborated the theoretical expectations, actually exceeded them, when taking the unfavourable psychometric characteristics of non-average IPR indicators into account.

Keywords: information processing rate, indicators of information processing rate dynamics, fluid intelligence, Big Five Personality Traits

Sadržaj

Uvod 2

Brzina obrade podataka 4

Perceptivna brzina 6

Fluidna inteligencija 7

Velepetore osobine ličnosti 8

BOP, um i inteligencija 9

Teorijski modeli odnosa inteligencije i osobina ličnosti 11

BOP i osobine ličnosti 14

Pokazatelji dinamike funkcioniranja kognitivno-motoričkog sustava u osnovi BOP-a 15

Cilj i problemi 18

Metoda 19

Sudionici 19

Instrumenti 22

D-2000 22

IPIP50 23

KS2-2 24

Postupak 26

Rezultati 27

Rasprava 34

Zaključak 44

Popis literature 47

Prilog 50

Uvod

Obrada podataka nezaobilazan je pojam u kognitivnoj psihologiji i znanosti koja proizlazi iz paradigmatskog okvira proučavanja uma kao sustava obrade podataka. U ovom diplomskom radu je brzina obrade podataka (BOP), mjerena perceptivnom brzinom (PB), ključni konstrukt, predstavljen i operacionaliziran različitim pokazateljima BOP-a. Radi njegovog sveobuhvatnijeg teorijskog sagledavanja analiziran je i odnos BOP-a s fluidnom inteligencijom (g_f) i osobinama ličnosti. U preglednom radu o konstruktu BOP-a, Žebec (2004) ističe kako je BOP bio predmet proučavanja u barem četiri područja psihologijskih istraživanja: inteligencije, eksperimentalne kognitivne psihologije, psihologije starenja i razvojne psihologije.

Thurstoneov model inteligencije uključivao je PB kao zasebni čimbenik inteligencije, Horn i Cattell (Woodcock, 1994, prema Žebec, 2004) te Carroll (1993) brzinu obrade smatraju faktorom drugog reda, a što je i slučaj za objedinjeni, CHC model inteligencije.

Unutar eksperimentalne kognitivne psihologije (radi cjelovitog i konzistentnog prikaza ljudske spoznaje u paradigmi čovjekove obrade podataka) provedeni su brojni eksperimenti namijenjeni raščlambi različitih kognitivnih podsustava (Vernon, 1994; Shepard i Metzler, 1971; Sternberg, 1966; Posner i Mitchell, 1967, prema Žebec, 2004), a vrijeme rješavanja zadataka u tim podsustavima predstavlja BOP unutar tih podsustava. Kako je obrada podataka osnovno svojstvo svih kognitivnih (pod)sustava, istraživači tog područja su proučavali i odnos BOP-a s drugim važnim konstruktima, poput kapaciteta radnog pamćenja (Hitch i sur., 1989, prema Žebec, 2004).

Odnos BOP-a i radnog pamćenja bio je predmet interesa i psihologije starenja (Salthouse, 1991, prema Žebec, 2004), a BOP se u tom istraživačkom području pokazao kao važan čimbenik dobnih promjena u različitim kognitivnim procesima. Žebec (2004) ističe primjer modela kognitivnog usporavanja u odrasloj dobi temeljen na BOP-u (Myerson i sur., 1990; Salthouse, 1996, prema Žebec, 2004).

Nadalje, unutar paradigme ljudske obrade podataka, BOP je, uz radno pamćenje, za kognitivni razvoj bio glavni konstrukt od interesa (Žebec, 2004). Jedan od ključnih zadataka ovog istraživačkog polja je otkrivanje mehanizama razvoja BOP-a, a taj se konstrukt javlja i u suvremenom Demetriouovom modelu uma opisanoga kao dinamički sustav s tri razine koje sinergijski djeluju u svakom zadatku, pri čemu osnovna razina uključuje upravo obradu podataka (Demetriou i sur., 2018).

U okviru razmatranja moguće biološke osnove BOP-a, postoje neke naznake da bi povezanost smanjene djelotvornosti bijele materije u mozgu i opće inteligencije mogla biti uzrokovana smanjenom BOP (Penke i sur., 2012), a Luciano i sur. (2005) su predložili da je kovarijaca vremena inspekcije (IT) (mjera BOP-a) i IQ-a uzrokovana genima koji utječu na strukturalne čimbenike mozga u podlozi brze obrade, kao što je kvaliteta mijelinskih ovojnica. BOP se i u kliničkim studijima pokazuje kao bitan prediktor različitih bolesti i aspekata bolesti, jer je visoko prediktivan za kliničke aspekte multiple skleroze, kao i za socijalnu potporu osoba oboljelih od multiple skleroze, a osobe s većom razinom motornih onesposobljenosti, depresijom i umorom imaju sporu obradu podataka (Eizaguirre i sur., 2018). Uz to su utvrđene razlike u BOP-u kod djece s ADHD-om, autizmom, bipolarnim poremećajem, depresijom, poremećajima učenja i mozgovnim oštećenjima, u odnosu na normalnu populaciju (Calhoun i Mayes, 2005).

Međutim, široka prisutnost BOP-a u raznim vidovima čovjekova kognitivnog funkcioniranja nije ujedno i dokaz njezine precizne teorijske definicije (modela) i konzistentnih operacionalizacija. Naime, u psihologijskoj literaturi se BOP pojavljuje pod najmanje sedam različitih naziva i operacionaliziran je s barem 98 različitih mjera, a istraživanja BOP-a nerijetko u potpunosti izostavljaju definiciju BOP-a (Žebec, 2004). Dodatni problem u nejednoznačnom poimanju BOP-a proizlazi iz metodološki različitog istraživanja globalnih nasuprot područno-specifičnih dobnih promjena BOP-a. Autori koji BOP istražuju iz očišta globalnih promjena uglavnom koriste ponašajne mjere BOP-a, a područno-specifični teoretičari koriste matematičke simulacije i psihofiziološke mjere. Zbog gore opisanih brojnih operacionalizacija BOP-a, Salthouse (2000, prema Žebec, 2004) je klasificirao različite mjere BOP-a na sljedeći način: brzina odluke, perceptivna brzina, psihomotorička brzina, kronometrijska brzina, psihofizička brzina i psihofiziološke mjere brzine.

Budući da se u mjerenju BOP-a uglavnom koriste prosječni pokazatelji (Jensen, 2007), opravdano je pridonijeti teorijskom modelu BOP-a promatranjem njegovih neprosječnih pokazatelja (nestabilnosti BOP sustava i otpornost BOP sustava na djelovanje nepovoljnih čimbenika), tj., istraživanjem (konvergentne) valjanosti prosječnih i neprosječnih pokazatelja BOP-a, istraživanjem zasebnih doprinosa tih pokazatelja predviđanju fluidne inteligencije, te odnosa tih pokazatelja s osobinama ličnosti. Sheppard i Vernon (2008) su pokazali da istraživanja odnosa BOP-a i inteligencije daju dosljedne niske korelacije i da različite mjere BOP-a na vrlo sličan način koreliraju s fluidnom inteligencijom (brže osobe u prosjeku imaju nešto višu fluidnu inteligenciju). Postoji i niz istraživanja u kojima je intraindividualni

varijabilitet vremena reakcije (RT-a) dijelio veću korelaciju s mjerama inteligencije, nego što prosječni RT dijeli s inteligencijom. (Barrett, Eysenck i Lucking, 1986, Jensen, 1987, prema Larson i Alderton, 1990). Larson i Alderton (1990) su raščlambom pojedinčevog RT-a (na jednostavnim kognitivnim zadacima) po brzini (u šesnaest kategorija, od pet najbržih RT-a, do pet najsporijih RT-a) otkrili da najsporiji RT bolje predviđa inteligenciju od najbržeg RT-a, te da korelacija RT-a i inteligencije linearno raste što su sporiji RT-i. Tu pojavu su nazvali „*worst performance rule"* ili pravilo najlošijeg uratka, a to pravilo je potvrđeno i u drugim istraživanjima (Kranzler, 1992). Različita istraživanja su mjerila odnos ličnosti, BOP-a i inteligencije. Primjerice, cilj istraživanja Reevea, Meyera i Bonaccija (2006) je bio ispitati mijenjaju li se korelacije ličnosti i specifičnih faktora inteligencije kada se iz tog odnosa izolira njihova veza s *g* faktorom. To su i potvrdili te pokazali da je faktor brzine najviše koreliran s ekstraverzijom, savjesnošću i intelektom kada se izolira g-faktor. S druge strane model Chamorro-Premuzica i sur. (2004) pretpostavlja nisku negativnu korelaciju mjere BOP-a (kao faktora inteligencije) s neuroticizmom, te nisku pozitivnu korelaciju mjere BOP-a (dobivene iz testa inteligencije) s ekstraverzijom. Taj model pretpostavlja nisku negativnu korelaciju savjesnosti i BOP-a (kada se BOP mjeri kao dio fluidne inteligencije), kao i nultu korelaciju između mjere BOP-a te intelekta i ugodnosti (jer intelekt i ugodnost ne koreliraju ni s *g* faktorom, ni s g_f – dvije mjere inteligencije koje jesu korelirane s BOP-om). Za razliku od ta dva modela, Demetriou i sur. (2010) pretpostavljaju niske ili nulte korelacije između BOP-a i osobina ličnosti jer ne pripadaju istim razinama uma. Stoga se u ovom radu dodatno istražuje odnos tri vida kognitivno-motoričkog sustava u osnovi PB-a (prosječna djelotvornost, nestabilnost i otpornost na pogreške i omaške) s tri osobine ličnosti, potencijalno relevantne za uspjeh u testu PB-a – intelektom, emocionalnom stabilnošću i savjesnošću.

Brzina obrade podataka

Brzina obrade podataka predstavlja mjeru djelotvornosti neke kognitivne funkcije (Sweet, 2011). Demetriou, Christou, Spanoudis i Platsidou (2002) definiraju BOP kao maksimalnu brzinu kojom se dana psihička aktivnost može djelotvorno izvršiti. Madden (2001) opisuje BOP kao glavno svojstvo središnjeg živčanog sustava, a RT kao mjere te brzine. Danthiir, Wilhelm, Schulze i Roberts navode (2005) kako ne postoji suglasje o tome je li BOP jedinstveni ili višedimenzionalni konstrukt, a njihova faktorska analiza različitih mjera BOP-a pokazuje četiri faktora prvog reda i jedan faktor drugog reda, koji se može opisati kao općenita

brzina obrade podataka. BOP se mjeri vremenski ograničenim testovima u kojima se od sudionika traži da odgovore na prilično jednostavne kognitivne operacije. Može se iskazati u terminima vremena reakcije (RT) ili broja točno odgovorenih zadataka (ograničene u nekom vremenu), ali i IT-om. Mjerenja se mogu vršiti pomoću računala i strojeva ili putem papir-olovka testova. Mead i Drasgow (2005) su dobili razliku ovisno o korištenim medijima (računalo ili papir-olovka test) u slučajevima testova brzine (r = 0,72) iz čega je vidljivo da je itekako značajan dio (50%) varijance istog testa brzine neobjašnjeno ako se koriste različiti mediji, ali je ta razlika među medijima testiranja izostala u usporedbama testova snage (r = 0,95). Glavna mjera BOP-a je RT i istraživanja RT-a sežu do samih početaka znanstvene psihologije, odnosno, Dondersovih istraživanja RT-a (Jensen, 2007). Jensen (2007) definira RT kao vrijeme između trenutka pojave podražaja na koji se traži odgovor i trenutka u kojem osoba na mjerljiv način odgovora. Ono uključuje prijenos signala, ali i neuralno procesiranje putem različitih perceptivnih, motoričkih i kognitivnih područja moždane kore. Drenovac (2009) navodi kako se RT sastoji od ukupnog potrebnog vremena za dane fiziološke procese u podlozi reakcije – od vremena u kojem receptor oblikuje informaciju danog podražaja, vremena prijenosa impulsa do moždane kore, vremena obrade sadržaja na razini kore, vremena potrebnog za stvaranje smjernice za odgovor na obrađeni sadržaj, vremena prijenosa impulsa do efektora i vremena potrebnog za pojavu odgovora u efektoru.

Zbog određenih problematičnih aspekata koji se javljaju u istraživanjima konstrukta BOP-a, Žebec (2004) predlaže novi koncept BOP-a u kojem je taj konstrukt definiran kao brzina kognitivnog procesa i predstavlja opće svojstvo svakoga kognitivnog procesa, javlja se u izvršenju bilo kojega kognitivnog zadatka, a mjeri se kao prosjek tri najkraća vremena reakcije. Budući da BOP proizlazi iz vremenskog određenja nekoga kognitivnog procesa, on ima barem tri dodatna svojstva, a to su stabilnost, izdržljivost i prilagodljivost kognitivnog procesa. Stabilnost kognitivnog procesa je definiran kao prosječna varijacija vremena reakcije uspješno izvršenih kognitivnih zadataka (koji izazivaju pripadni kognitivni proces). Prilagodljivost kognitivnog procesa je definirana kao smanjenje vremena uspješnog izvršenja kognitivnog zadatka (koji izaziva pripadni kognitivni proces) s povećanjem broja zadataka. Konačno, izdržljivost kognitivnog procesa je negativno definirana kao povećanje vremena uspješnog izvršavanja kognitivnog zadatka (koji izaziva pripadni kognitivni proces) s povećanjem broja zadataka.

Iz navedene nove konceptualizacije BOP-a proizlaze dva neprosječna pokazatelja korištena u ovom diplomskom radu, a to su nestabilnost kognitivno-motoričkog sustava BOP

mjerena intraindividualnim varijabilitetom (IIV-om) odgovora na testu PB-a i izdržljivost ili otpornost kognitivno-motoričkog sustava BOP mjerena omjerom prosjeka rednog broja prve dvije pogreške/omaške (otpornost sustava je iskazana pomoću dva pokazatelja: otpornost pogreškama i otpornost omaškama) i rednog broja zadnje riješenog zadatka. Korišteni neprosječni pokazatelji BOP-sustava u ovom radu su dodatno opisani na kraju Uvoda i u Metodi.

Perceptivna brzina

Budući da je vid glavni osjet i modalitet percepcije čovjeka te da je korišteni test perceptivne brzine zahtijevao vidnu obradu, u ovom radu se PB objašnjava putem te vrste percepcije, iako takva definicija ispušta druge važne oblike perceptivne obrade, kao što je slušno perceptivno područje. U tom pogledu je PB kognitivna sposobnost definirana kao „brzina usporedbe likova ili simbola, pretraživanje kako bi se pronašli likovi ili simboli, ili izvršavanje jednostavnih zadataka koje uključuju vizualnu percepciju“ (Ekstrom i sur., 1976, prema Allen, 1994). Ona se može opisati kao jedan aspekt i učestala mjera BOP-a. Ackerman navodi (1999) kako je teoretski vrijedno istraživati PB jer predstavlja slabo poznato područje ljudskih sposobnosti, a praktična vrijednost očitovana je u prediktivnoj snazi mjera PB-a za uspjeh u treninzima vještina i u samom razvoju niza vještina (od složenih kognitivnih vještina do vještina fine motorike). Teoretski je nejasno je li perceptivna brzina višedimenzionalni konstrukt ili ne. Međutim, vjerojatno je riječ o višedimenzionalnom konstruktu što pokazuje istraživanje Ackermana, Beiera i Boylea (2002). Autori su u svom radu dobili četiri faktora (prvog reda) perceptivne brzine: PB pretraživanja, složena PB, PB prepoznavanja uzoraka i PB pamćenja. Faktor drugog reda bila je obična perceptivna brzina i korelirala je s radnim pamćenjem i *g* faktorom (Ackerman i sur., 2002). U objašnjenjima dijeljene varijance mjera radnog pamćenja i *g* faktora su istraživači poput Kail i Salthouse (1994) i Jensen (1998) (prema Ackerman i sur., 2002) predložili da PB (kao mjera BOP-a) ograničava radno pamćenje i da je PB (odnosno BOP) kauzalni mehanizam u podlozi dijeljene varijance radnog pamćenja i *g* faktora. Drugi istraživači (Conway, Kane i Engle, 1999, prema Ackerman i sur., 2002) predlažu suprotno: radno pamćenje ograničava BOP. Ackerman i sur. (2002) tvrde da su oba objašnjenja neodgovarajuća, zato što je PB višedimenzionalan konstrukt čiji faktori dijele zajedničku varijancu s BOP-om, ali ni jedan nije isključivo asociran s BOP-om. Osim toga, u radu (Ackerman i sur., 2002) su tri od četiri dobivena faktora PB-a dijelila zasebnu varijancu s radnim pamćenjem i zasebnu varijancu s *g* faktorom.

Primjer praktične vrijednosti istraživanja PB-a je inkrementalna valjanost jednog testa PB-a u predviđanju radnog učinka kontrolora leta u laboratorijskim uvjetima i na terenu (Ackerman i Kanfer, 1993, Ackerman, Kanfer i Goff, 1995, prema Ackerman, 1999). Dodatni primjer je istraživanje dobnih promjena u PB-u na hrvatskim strojovođama Žebeca, Palavre i Sumpora (2016) u kojem se pokazalo kako su prosječni i neprosječni indikatori psihometrijski osjetljive i valjane mjere i da se pomoću njih dobiva sveobuhvatniji uvid starosnih promjena u PB-u.

Fluidna inteligencija

Fludina inteligencija je kapacitet za logičko razmišljanje i rješavanja problema u novim situacijama gdje ne postoji utjecaj stečenog znanja (Cattell, 1987, prema Ferrer, 2009). Chammoro-Premuzic, Stumm i Fournham (2015) definiraju fluidnu inteligenciju kao „sposobnost primjene pravila i premisa u svrhu rješavanja problema; sposobnost otkrivanja latentnih osobina u podlozi problema“. Dodatno spominju kako je ona zapravo jednaka *g* faktoru. Fluidna inteligencija predviđa uspješnost u cijelom nizu svakodnevnih aktivnosti i životno važnim zadacima i izazovima, poput obrazovanja i profesionalnog razvoja (Gottfredson, 1997). Mjeri se na različite načine, a Ferrer (2009) spominje Ravenove progresivne matrice kao najučestaliju mjeru. Taj test mjeri sposobnost promišljanja o jednoj ili više umnih reprezentacija, odnosno, sposobnost apstraktnog rezoniranja. Vjeruje se da fluidna inteligencija nastaje nakon razvoja kompetencija pažnje i perceptivno motoričkih kompetencija između druge i treće godine (Cattel, 1987, prema Ferrer, 2009). Naglo se razvija u ranom i srednjem djetinjstvu i nakon adolescencije blago pada do starosti, kada počinje jače opadati (McArdle i sur, 2002, prema Ferrer, 2009). Fluidna inteligencija čini podlogu na koju se iskustvom kristaliziraju vještine i znanje. Longitudinalna istraživanja djece i adolescenata ukazuju na vodeću ulogu fluidne inteligencije u vremenskim promjenama kristaliziranih sposobnosti, ali i promjena u kvantitativnim sposobnostima, akademskom znanju i čitanju (McArdle i sur., 2000; Ferrer i McArdle, 2004; Ferrer i sur., 2007, prema Ferrer, 2009). Ferrer (2009) spominje i moguće sinergijske utjecaje fluidne inteligencije s radnim pamćenjem i BOP-om (Demetriou, 2002). Longitudinalna istraživanja Demetrioua (2002) pokazuju da je fluidna inteligencija najbliže vezana uz BOP i radno pamćenje, a istraživanja pripadnih neuralnih osnova pokazuju kako je čeoni režanj bitno asociran s fluidnom inteligencijom (Duncan, 2005, prema Ferrer, 2009). Područje anteriornog prefrontalnog korteksa poznat kao rostrolateralni prefrontalni korteks uključen je u zadacima Ravenovih progresivnih matrica koje zahtijevaju

apstraktno rezoniranje, tj., relacijsku integraciju (Christoff i sur, 2001, Kroger i sur., 2002). To isto područje je uključeno i u drugim zadacima koji mjere fluidnu inteligenciju a odnose se na apstraktno rezoniranje (Ferrer, 2009).

Velepetore osobine ličnosti

Osobina ličnosti se odnosi na primjetnu dosljednost u razmišljanju, osjećanju i ponašanju koje je relativno trajno i ne ovisi o situaciji (Caspi, 1998, prema Chammoro-Premuzic i sur., 2015). Velepetori model ličnosti je među najčešće korištenim modelima (Saucier, 2003, prema Chammoro-Premuzic i sur., 2015), a svaka osobina uključuje niz faceta, odnosno, niz povezanih ponašajnih sklonosti. U stranoj literaturi se te osobine uglavnom odnose na mjere dobivene upitnik koji su razvili McCrae i Costa (1999), odnosno pet-faktorskom modelu, a tih pet dimenzija ličnosti su analogne osobinama iz modela velepetorih osobina koje je razvio Goldberg (1990). Jedna razlika je da se intelekt odnosi na osobinu ličnosti koji je dobiven leksičkim pristupom ličnosti (Goldberg, 1990), dok je otvorenost prema iskustvu analogna osobina iz pet-faktorskog modela McCrae i Coste (1999). Intelekt i otvorenost prema iskustvu predstavljaju različite aspekte šireg područja ličnosti (John i Srivastava, 1999, prema Žebec i sur., 2011). U ovom radu se zbog jednostavnosti koristi naziv intelekt čak i kada postoji referenca na rad koji je ličnost mjerio pet-faktorskim modelom, tj., kada je mjerena otvorenost prema iskustvu. Drugim riječima se ta dva aspekta u ovom pregledu istraživanja tretiraju kao jedan te isti, premda je u empirijskom dijelu rada mjerena osobina intelekt.

Savjesnost se odnosi na sklonosti u pogledu ponašanja vezana uz organizaciju rada, produktivnosti i odgovornosti. Visoko savjesni pojedinci preferiraju red i strukturu, te marljivo i predano rade kako bi ostvarili neki zadani cilj (Soto, 2018).

Chammoro-Premuzic i sur. (2015) definiraju intelekt kao osobinu koja pretpostavlja intelektualnu znatiželju, estetsku svjesnost i umjetničke interese. Pojedinci s tim osobinama preferiraju intelektualno stimulirajuću okolinu i zato vole učiti, što može rezultirati većim znanjem i kristaliziranom inteligencijom.

Emocionalna stabilnost označava pozitivnu emocionalnost i stupanj otpornosti osobe na doživljavanje negativnih emocija, a može se opisati kao suprotni pol neuroticizma. Neuroticizam obuhvaća sklonost tjeskobi, tuzi, stresu i drugim neugodnim emocijama (Soto, 2018).

Kognitivne sposobnosti i osobine ličnosti povezane su s uratkom na zadacima, pri čemu je uradak definiran kao „spretnost s kojom osobe obavljaju radne zadatke svog posla; aktivnosti koje posredno ili neposredno doprinose organizaciji.“ (Borman i Motowidlo, 1997, prema Chammoro-Premuzic i sur., 2015). Dok je općenito točno da kognitivne sposobnosti u većoj mjeri koreliraju s uspješnim uratkom na različitim zadacima, savjesnost, emocionalna stabilnost i intelekt svakako doprinose uratku na zadacima (Chammoro-Premuzic i sur., 2015).

BOP, um i inteligencija

Demetriou i sur. (2010) spominju tri epistemološki različite tradicije istraživanja obrade podataka: eksperimentalnu, diferencijalnu i razvojnu. Unutar eksperimentalne tradicije je težište stavljeno na istraživanju dinamičkih aspekata umnih funkcija kako bi se objasnili načini primanja, obrade, reprezentacije i pohrane podataka iz okoline u svrhu razumijevanja i rješavanja problema. Brzina obrade podataka, selektivna pažnja i radno pamćenje su ključni konstrukti od interesa ove tradicije i jedan primjer eskperimentalnog modela koji je i danas aktualan je Baddeleyjev model radnog pamćenja (Baddeley, 1990, 2000, prema Demetriou i sur., 2010). Druga tradicija, diferencijalna ili psihometrijska, naglasak istraživanja usmjerila je na mjerenju i objašnjavanju individualnih razlika u psihičkim osobinama. Jedna je teorija inteligencije iz ove tradicije i danas aktualna, a to je CHC teorija inteligencije nastala integracijom dvaju prethodnih, diferencijalnih modela inteligencije: teorije fluidne i kristalizirane inteligencije i Carrollove (1993) trorazinske teorije inteligencije. Iako je Carroll prihvaćao Cattell-Hornovu podjelu inteligencije na fluidnu i kristaliziranu, imali su neke razlike, kao što je prihvaćanje g faktora od strane Carrolla, ali odbacivanje tog pojma sa strane Cattella i Horna. Integraciju modela prvi čini McGrew (1997), a unutar tog modela se inteligencija objašnjava kroz tri razine kognicije, od najšire razine opće inteligencije, do najuže razine u podlozi određenih vrsta zadataka. Na najširoj razini se nalazi g faktor, koji je u podlozi svih devet sposobnosti druge razine. Druga razina se odnosi na „osnovne sastavnice i postojane osobine pojedinaca koje mogu upravljati s - ili utjecati na - veliki broj ponašanja iz određenog područja“ (Carroll, 1993, str. 634). Tu se nalazi g_f i g_c, ali i vizualna obrada, auditorna obrada i brzina obrade podataka. Unutar Carrolove teorije (1993) se spominje i deseti faktor – vrijeme reakcije (RT) ili brzina koja se odnosi na brzinu odgovaranja na podražaj ili zadatak. Na najužoj razini Carroll (1993) spominje perceptivnu brzinu koja proizlazi iz BOP-a. Korelacije BOP-a i g faktora variraju između -0,2 i -0,8 ovisno o složenosti zadatka koji mjeri BOP (Demetriou i

sur., 2010), odnosno, korelacija je veća što je veća složenost zadatka (Bors, McLeod i Forrin, 1993, prema Demetriou i sur., 2010). Zbog toga su neki istraživači tvrdili da je radno pamćenje, a ne BOP, odgovorno za tu korelaciju (Embretson, 1995, prema Demetriou i sur., 2010). Miller i Vernon (1992, prema Demetriou i sur., 2010) su pokazali da je radno pamćenje bolji prediktor g faktora od BOP-a, premda su istaknuli da je radno pamćenje medijator odnosa BOP-a i g faktora, jer je i ono samo temeljeno na BOP-u. U meta-analizi 50 godina istraživanja korelacijskih odnosa različitih prosječnih mjera BOP-a s inteligencijom su Sheppard i Vernon (2008) utvrdili da je RT dijelio veću korelaciju s fluidnom inteligencijom (r = -0,21), nego li s kristaliziranom inteligencijom (r = -0,17), što se očitovalo i u prosječnim korelacijama općenite brzine obrade podataka s g_f i g_c (r = -0,35 ; r = -0,16).

Konačno, treća tradicija istraživanja obrade podataka i uma jest razvojna tradicija. Ona se prvenstveno usmjerila na istraživanje razvoja psihičkih funkcija kako bi se ustanovila priroda različitih faza razvoja uma i dinamike kognitivnih procesa koje um poprima u različitim životnim fazama, kao i uzroke i mehanizme u podlozi razvojne transformacije. Klasična teorija ove tradicije je Piagetova teorija kognitivnog razvoja (Demetriou i sur., 2010), a s vremenom su rasli napori integriranja različitih tradicija s razvojnom tradicijom. Demetriou i sur. (2010) spominju dva istraživačka usmjerenja unutar tih napora: prva je naglasak stavila na ulogu BOP-a i inhibicije u razvoju mišljenja i vještina rješavanja problema; druga se usmjerila na ulogu radnog pamćenja i nazivaju se neo-piažeovskim teorijama.

Demetriou i sur. (2010) predlažu sveobuhvatnu teoriju uma koja um objašnjava kroz tri razine, pri čemu je svaka razina složena mreža procesa i sustava koje uključuje više dimenzija i redova organizacije. Najosnovnija razina uključuje općenite procese i funkcije, kao što je brzina i kontrola obrade podataka te kapacitet radnog pamćenja. Druga razina sadrži sustave kognitivnih funkcija i sposobnosti (različite vrste mišljenja) pogodne za reprezentaciju i obradu različitih vida prirodne i društvene okoline. Treća razina je slična drugoj, ali se odnosi na znanje o sebi. Ona uključuje procese u podlozi pažnje, svjesnosti, namjera i samokontrole, tj., procese u podlozi samopromatranja, slike o sebi i samoregulacije. U podlozi razumijevanja, učenja ili obavljanja bilo kojeg zadatka postoji amalgam procesa svih razina. Osnovna razina se naziva kapacitetima obrade i određena je trima dimenzijama: brzinom obrade, kontrolom obrade i kapacitetom reprezentacije, pri čemu se brzina obrade odnosi na najbržu moguću brzinu na kojoj se dana umna aktivnost može djelotvorno izvršiti. Kontrolirani procesi se odnose na inhibitorne mehanizme kao što je selektivna inhibicija nerelevantnih ili distraktorskih podražaja, inhibicija presnažnih ili preuranjenih odgovora, koncentracija na relevantne

informacije, prebacivanje pažnje itd. Reprezentacijski kapacitet odnosi se na najveću moguću količinu informacije i umnih aktivnosti koje um može djelotvorno aktivirati u danom trenutku, pri čemu je unutar ovog modela radno pamćenje funkcionalna manifestacija reprezentacijskoga kapaciteta.

Demetriou i sur. (2013) tvrde da se razvoj fluidne inteligencije može opisati putem višestrukog slijeda ili faza različitih ciklusa rekonceptualizacije. Demetriou i sur. (2014) pokazuju da su promjene g_f isprepleteni s promjenama u BOP-u na početku nekog ciklusa rekonceptualizacije i s promjenama radnog pamćenja na kraju ciklusa. Navode kako fluidna inteligencija prolazi tri vrste promjene: reprezentacijsku, inferencijalnu i promjenu složenosti.

Zaključno, BOP je konstrukt koji se javlja kao neophodna sastavnica proučavanja uma i unutar različitih modela inteligencije upravo kao sastavni čimbenik inteligencije, procesa rješavanja problema i općenito umnih procesa. Suvremeni CHC model inteligencije opisuje BOP kao faktor inteligencije i perceptivnu brzinu kao jednu od osnovnih pokazatelja BOP-a koji određuje uspješnost u zadacima koje mjere brzinu obrade podataka. Demetriouev model koji integrira diferencijalnu i razvojnu tradiciju isto određuje BOP kao osnovni proces uma i, uz radno pamćenje, čimbenik koji je vezan uz razvojne promjene fluidne inteligencije.

Teorijski modeli odnosa inteligencije i osobina ličnosti

Fournham, Moutafi i Chamorro-Premuzic (2005) navode kako se, usprkos uvriježenoj praksi razlikovanja konstrukata inteligencije i osobina ličnosti, mnogi se istraživači (iz psihometrijskog i kognitivno-znanstvenog pristupa) trude izraziti njihovu pojmovnu i empirijsku povezanost. Njihova povezanost proizlazi i iz nekih općenitih sličnosti.

Sličnost inteligencije i ličnosti očituje se u nekoliko aspekata. Kao prvo, oba konstrukta se odnose na kognitivne, afektivne i ponašajne razlike koje se mogu kvantificirati standardiziranim psihometrijskim instrumentima (Funder, 2001, prema Chammoro-Premuzic i sur., 2015). Kao drugo, u različitim mjerama su genetički determinirani (npr., Spinath i Johnson, 2011, Chammoro-Premuzic i sur., 2015). Treća sličnost je vremenska stabilnost (tijekom života) oba konstrukta. Četvrto, inteligencija i ličnost predviđaju individualne razlike u širokom rasponu životnih ishoda, kao što su obrazovni i profesionalni uspjeh, zdravlje i dugovječnost (Barrick i Mount, 1991; Calvin, Batty i Deary, 2011; Kern i Friedman, 2011; Poropat, 2009, prema Chammoro-Premuzic i sur., 2015). No, s druge strane postoje i bitne razlike među

konstruktima, kao što je činjenica da inteligencija mjeri najbolji učinak ili ono što osoba može napraviti, a ličnost mjeri tipična ili uobičajena ponašanja. Šira rasprava o razlikama konstrukata izlazi iz okvira ovog uvoda, u kojem predstoji prikaz dva modela koja konceptualiziraju odnos ličnosti i inteligencije.

Prvi model je taj Chamorro-Premuzica i Fournhama (2004) u kojem se odnos ličnosti i inteligencije opisuje u pogledu međusobnih utjecaja osobina ličnosti i, ono što autori nazivaju, tri različita vida inteligencije. Tri vida inteligencije u ovom modelu su, kao prvo, intelektualne sposobnosti (uključuje kristaliziranu i fluidnu inteligenciju), kao drugo, uradak na testovima IQ-a, a zadnji vid je samprocijenjena inteligencija. Ovaj model promatra odnos ličnosti i inteligencije pomoću nekoliko razina međusobnih (pretpostavljenih) odnosa tri (gore navedena) vida inteligencije i ličnosti. Za početak je pretpostavljeno da je uradak na testovima IQ-a prvenstveno odraz intelektualnih sposobnosti. Nadalje, uradak na testovima je pod utjecajem samoprocjene vlastite inteligencije, na način da niska samoprocjena inteligencije visoko inteligentnih osoba negativno utječe na uradak na IQ testu. Pritom je pretpostavljeno da je i samoprocjena inteligencije pod utjecajem prijašnjih uradaka na testu IQ-a (ali i poslovnih i akademskih uradaka), te učestalosti povratnih informacija. Treća razina odnosa pretpostavlja negativni učinak neuroticizma i pozitivni učinak ekstraverzije na uradak na testovima IQ-a, jer neurotične osobe proživljavaju više tjeskobe i stresa, a ekstraverti brže i asertivnije odgovaraju na zadatke i manje su podložni distraktorima poput buke. Sljedeća, četvrta razina pretpostavlja utjecaj osobina ličnosti na samoprocjenu inteligencije, a potonje je medijator odnosa ličnosti i inteligencije. Primjerice, neurotične osobe podcjenjuju svoju inteligenciju, a ekstraverti iskazuju veću samoprocjenu inteligencije zbog veće optimističnosti i samopouzdanosti. Zadnja razina odnosa pretpostavlja međudjelovanje ličnosti i intelektualnih sposobnosti (g_c i g_f). Neki aspekti savjesnosti i intelekta vezane su uz odluke o pristupanju intelektualno stimulirajućim okolinama, koje pozitivno djeluju (prvenstveno) na kristaliziranu inteligenciju. S druge strane postoji utjecaj intelektualnih sposobnosti na ličnost. Primjerice, negativna povezanost fluidne inteligencije i savjesnosti se pojavljuje jer savjesnost služi kao kompenzacija relativno lošijim intelektualnim sposobnostima, a osobe relativno većih intelektualnih sposobnosti manje vjerojatno razvijaju neke aspekte savjesne ličnosti (npr., organiziranost, odgovornost) jer im njihove razvijenije intelektualne sposobnosti pružaju dovoljan oslonac za postizanje važnih ciljeva.

Drugi model je predložen unutar trorazinske teorije uma Andreasa Demetrioua koja ima dodatnu prednost (u odnosu na model Fournhama i sur., 2004) promatranja odnosa ličnosti i

inteligencije kroz razvojno očište. Demetriou i sur. (2018) predlažu kako se slabi ili nedosljedni nalazi odnosa inteligencije i ličnosti daju pripisati razlikama u načinu mjerenja konstrukata: mjere inteligencije su odraz učinka, a mjere ličnosti odraz samoprocjene – povrh toga postoji razlika u preciznosti mjerenja (istraživača nasuprot sudionika). Autori ovog modela kritiziraju strogu razdiobu ličnosti i inteligencije, te predlažu da se za proučavanje odnosa inteligencije i ličnosti oni moraju proučavati na istoj razini, odnosno u kontekstu šire teorije uma i da se uz mjere učinka intelektualnih sposobnosti mjere i samoprocjene intelektualnih sposobnosti i metakognicija. U jednom radu (Demetriou i sur., 2003) su nastojali kognitivne sposobnosti i ličnost mjeriti kroz različita područja samosvjesnosti. Pretpostavljaju da velepetore osobine ličnosti korespondiraju područno-relevantnim sustavima razumijevanja (načinima mišljenja) okoline, i da postoji analogija između odnosa temperamenta i ličnosti, te odnosa kapaciteta obrade i inteligencije. Prošla istraživanja općenito pokazuju slabu vezu ličnosti i kognitivnih sposobnosti, odnosno, intelekt nisko i pozitivno, a savjesnost negativno korelira s kognitivnim sposobnostima: sličan nalaz je dobiven u radu Demetriou i sur. (2003) u kojem intelekt visoko korelirao sa slikom o vlastitim kognitivnim sposobnostima, a manje sa stvarnim sposobnostima, iz čega autori zaključuju da to pokazuje veću spremnost na izazove i nove situacije kod osoba koje se smatraju inteligentnijima. Odnosno, intelekt je funkcija prevođenja kognitivnih sposobnosti u ponašajne dispozicije vezane uz kognitivno funkcioniranje (Demetriou i sur., 2003). U kontekstu Demetrioueve teorije uma hipotetiziraju da razina uma koja se odnosi na razumijevanje sebe (hiperkognitivni sustav) ulazi u interakciju s ponašajnim sklonostima kako bi izgradio različite stilove učenja, ponašanja i samoregulacije tako da s vremenom gradi usmjeravajuća samopoimanja kroz: vještine rješavanja problema, dispozicije prilaženja ili izbjegavanja određenim ponašanjima ili okolinama, te povratnih informacija. Ta samopoimanja usmjeravaju osobe u odabir određenih uzoraka ponašanja i okoline koje su najprikladnije i nagrađujuće, te se ta samopoimanja na taj način grade kao najvaljanije reprezentacije sebe. U ovom modelu uzorci ponašanja i samoreprezentacije smatraju se nizom jedinstvenih skupova ili paketa koji uključuju splet sposobnosti, dispozicija, stilova i interesa.

U novom radu Demetriou i sur. (2018) se odnos inteligencije i ličnosti istražuje s obzirom na: faktorsku sličnost konstrukata, na međusobnim interakcijama sastavnih procesa konstrukata, na općenitom povezujućem medijatoru u podlozi interakcije, kao što je *cognizance* ili samosvjesnost (uključuje skup procesa kao što je samoregulacija, samoreprezentacija, metareprezentaciju itd.), te s obzirom na prediktivnu ulogu inteligencije i ličnosti u životnim ishodima poput obrazovanja. Strukturna (faktorska) sličnost inteligencije i ličnosti vidljiva je u

tome da trorazinska struktura inteligencije korespondira hijerahijskom modelu ličnost u kojem su savjesnost, neuroticizam i ugodnost saturirane faktorom stabilnosti ili alfa-faktorom; a intelekt i ekstraverzija saturirane faktorom prilagodljivosti ili beta-faktorom, pri čemu alfa i beta faktori čine generalni faktor ličnosti. U radu (Demetriou, 2018) iznose dokaze o povezanosti *g* faktora i generalnog faktora ličnosti. Nadalje, pretpostavljaju da procesi izvršne kontrole i samosvjesnosti djeluju i kod inteligencije i kod ličnosti. Izvršna kontrola je ključna sastavnica fluidne inteligencije, ali se nalazi i u podlozi samodiscipline i stabilnosti (kod savjesnosti), održavanja prilagodljivosti u međuljudskim interakcijama (kod ekstraverzije), te prilagodljivosti u suočavanju s novim situacijama (kod intelekta). Samosvjesnost se opisuje kao samopoimajući sustav sastavljen od: vještina i procesa rješavanja problema, sklonosti prilaženju ili izbjegavanju određenih uzoraka ponašanja, te povratnih informacija o stupnju uspješnosti uz koje se vežu pripadni osjećaji (ne)zadovoljstva. Promjena samosvjesnosti korespondira s razvojnim promjenama u načinu razmišljanja, odnosno u kognitivnom razvoju, a s porastom dobi slika o sebi postaje sve preciznije i bolja u otkrivanju vlastitih snaga i slabosti. U ovom modelu je naglašen dvosmjerni utjecaj ličnosti i inteligencije, a pretpostavljeno je da su određene osobine više povezane s određenim kognitivnim procesima, kao što je slučaj savjesnosti i g_f.

BOP i osobine ličnosti

Budući da je BOP dio fluidne inteligencije, logično je očekivati da će se donekle slične korelacije javljati u odnosima BOP-a i ličnosti. Derakshan i Eysenck (2009) su naveli niz dokaza utjecaja tjeskobe na obradu podataka. Napominju da su istraživanja pokazala kako je tjeskoba asocirana s negativnim posljedicama na kognitivni učinak, pogotovo na učinak na zadacima koji zahtijevaju preusmjeravanje pažnje. Postoje dokazi da tjeskoba remeti djelotvornost obrade više nego učinak na zadatku, a isto tako remeti inhibicijske funkcije i učinak na zadacima u kojima se brzo izmjenjuju različite vrste zadataka (u odnosu na blok istih zadataka) (Derakshan i Eysenck, 2009).

Žebec i sur. (2011) pregledom istraživanja odnosa BOP- a i ličnosti ističu nekoliko odlika tih radova. Kao prvo, istraživanja odnosa BOP-a i osobina ličnosti često se razlikuju po teoretskom modelu odnosa BOP-a i intelektualnog funkcioniranja, ali pokazuju da BOP ima zasebnu ulogu u tom odnosu. Zatim naglašavaju kako istraživanja daju različite i nedosljedne nalaze o odnosu BOP-a i ličnosti koje su funkcija korištenih (različitih) mjera, a osim toga ta

istraživanja nisu promatrala odnos BOP-a i ličnosti u pogledu razvojnih pitanja usprkos postojećim modelima koje integriraju diferencijalni i razvojni aspekt odnosa intelektualnih sposobnosti i ličnosti (Demetriou i sur., 1999; Demetriou i sur., 2003, prema Žebec i sur., 2011). Žebec i sur. (2011) su na uzorku adolescenata različite dobi pokazali da je korelacija ekstraverzije i BOP-a najstabilnija kroz različite dobi, pri čemu su ekstraverti bolje rješavali test perceptivne brzine, što je objašnjivo motornim zahtjevima testa i Eysenckove pretpostavke (1967, prema Žebec i sur., 2011) viših rezultata ekstraverata u uvjetima većeg uzbuđenja (u slučaju njihovog rada se može pretpostaviti da je uzbuđenje inducirano razrednim natjecanjem). S druge strane, odbacili su hipotezu obrnute U-raspodjele ekstraverzije i BOP-a. Nisu dobivene značajne korelacije između BOP-a i emocionalne stabilnosti (što je u skladu s drugim radovima odnosa neuroticizma i BOP-a koja pokazuju nultu korelaciju ili vrlo nisku korelaciju s neznačajnom količinom objašnjene varijance), te BOP-a i savjesnosti. Intelekt i g_f ne koreliraju prema modelu Chamorro-Premuzica i Fournhama (2004), a g_f korelira s BOP-om, odnosno, BOP je jedna od sastavnica fluidne inteligencije, iz čega ti istraživači zaključuju da ni među mjerama BOP-a i intelekta nema povezanosti. Ta pretpostavaka modela Chamorro-Premuzica i Fournhama (2004) je potvrđena u radu Žebeca i sur. (2011) jer nisu dobili korelaciju mjere BOP-a i intelekta. Dakle, taj model je potvrđen u pogledu niske pozitivne korelacije ekstraverzije i nepostojeće korelacije s intelektom, a nulta korelacija s ugodnošću je djelomično potvrđena (dobivena je niska korelacija). No, model nije potvrđen u pogledu očekivane negativne korelacije BOP-a s neuroticizmom i savjesnošću. Podaci Žebec i sur. (2011) prilično se dobro uklapaju u model Demetriou i sur. (2003) koji predviđa nulte (ili niske) korelacije BOP-a i samoprocijenjene ličnosti iz razloga što pripadaju različitim razinama uma.

Pokazatelji dinamike funkcioniranja kognitivno-motoričkog sustava u osnovi BOP-a

Empirijska istraživanja BOP-a koja koriste vrijeme reakcije (RT) na pojedini zadatak u testu BOP-a, BOP uglavnom mjere prosječnim RT-om u svim zadacima. Jensen navodi kako je RT uglavnom mjeren aritmetičkom sredinom ili medijanom i da je intraindividualni varijabilitet RT-a (RTSD) često zanemaren ili tretiran kao pogreška RT-a (Jensen, 2007). Zbog toga je odnos RTSD i drugih varijabli, poput inteligencije, ostao prilično neistražen (Reed, 1998; Jensen, 2007). On, nadalje, naglašava kako između prosječnih mjera RT-a i RTSD-a najčešće postoje visoke korelacije, što bi moglo upućivati na suvišnost jedne od tih varijabli; no, postoje razlozi za jasnu raščlambu tih varijabli. Primjerice, Rammsayer i Troche (2010) temeljem rezultata dobivenih modeliranom strukturalnom jednadžbom zaključuju kako RTmd i RTSD

odražavaju dvije različite izvore varijance psihometrijskoga *g* faktora. Do istog zaključka dolazi i Jensen (1992) koji smatra da je, među ostalim, jedan od pokazatelja zasebnosti RTmd-a i RTSD-a taj da su u njegovom radu RTmd i RTSD zajedno dali značajno veću multiplu korelaciju s *g* faktorom, u odnosu na običnu korelaciju što ih pojedini konstrukti dijele s *g* faktorom. Jensen (2007) ističe važnost istraživanja RTSD, napose zbog značajne povezanosti što ju ona dijeli s IQ-om – i to neovisno o RT-u. Još jedan primjer relevantnosti intraindividualnog varijabiliteta BOP-a u istraživanjima *g* faktora je Schweizerov rad (1993) u kojem je dobio značajne korelacije IIV-a BOP-a i rezultata različitih ljestvica inteligencije, a koje su mjerile faktore inteligencije sukladne Thurstoneovom modelu inteligencije (jedna od faktora je perceptivna brzina). Pritom su prosječan (M) i neprosječan (SD) pokazatelj BOP-a visoko korelirali, što ograničava konstruktnu valjanost nestabilnosti u tom radu.

Na široj teorijskoj razini se IIV pokazao važnim za istraživanje dinamičkih konstrukata i procesa (Diehl, Hooker i Sliwinski, 2015). Ono predstavlja kratkoročne promjene koje se događaju u kratkim vremenskim razmacima (Nesselroade, 1991, prema Diehl i sur., 2015), odnosno, odražava varijabilitet nekoga konstrukta tijekom vremena unutar jedne osobe. Ram i Gerstorf (2009, prema Diehl i sur., 2015) su predložili da vremenski strukturiran IIV odražava dinamičke procese koje prate određene vremenske tokove, a obični IIV prije odražava deskriptivne dinamičke osobine neovisne o nekom sustavnom vremenskom toku. Diehl i sur. (2015) navode kako je u IIV predmet velikog interesa u istraživanjima kognicije odrasle dobi i starenja, a isto tako je bio prediktivan za tretmanski-vezana poboljšanja u kogniciji odraslih osoba (Allaire i Marsiske, 2005, prema Diehl i sur., 2015). IIV uratka na senzo-motoričkim zadacima činio je barem polovicu promatrane varijacije u uratku koji se dade pripisati individualnim razlikama, i 25-50% varijacije na perceptivno-motoričkim zadacima. (Li, Aggen i sur., 2001; Nesselroade i Salthouse, 2004, prema Diehl i sur., 2015). IIV se pokazao vremenski relativno stabilnom pojavom (Allaire i Marsiske, 2005; Li, Aggen i sur., 2001, prema Diehl i sur., 2015). Korištenje IIV proizlazi, uostalom, iz toga da bi prosječni indikatori uratka na nekom kognitivnom zadatku mogli predstavljati preveliko pojednostavljenje uzoraka u ponašanja, te da ispuštaju teoretski zanimljive aspekte kognitivnog funkcioniranja (Nesselroade i Featherman, 1997; Garret, Kovacenic, McIntosh i Grady, 2010, prema Diehl i sur., 2015).

Žebec i suradnici (Žebec, Budimir, Merkaš, Szirovitzca, Živičnjak, 2014; Žebec, Crnko, Palavra, Sumpor, 2017) empirijskim su radovima opravdali uvođenje dodatnih ne-prosječnih pokazatelja u procjenjivanju BOP-a, ali i selektivne pažnje. U tom smislu, za svrhe ovog rada posebno je zanimljiv članak s indikatorima dinamike funkcioniranja selektivne pažnje (Žebec i

sur., 2017) jer koristi slične papir-olovka mjere kognitivnog funkcioniranja, ali i pokazatelje dinamike funkcioniranja istraživanog kognitivnog sustava: prosječna djelotvornost, nestabilnost i otpornost na djelovanje nepovoljnih čimbenika.

Temeljem prethodno navedenoga, u ovom radu koriste se sljedeći pokazatelji dinamike funkcioniranja kognitivno-motoričkog sustava u osnovi BOP-a:

- *Prosječna djelotvornost* kognitivno-motoričkog sustava pri realizaciji BOP zadatka (PD-BOP) je ukupan uradak kognitivno-motoričkog sustava na nizu ekvivalentnih BOP-zadataka u jedinici vremena, te veći broj točno riješenih BOP-zadataka odražava veću PD-BOP.
- *Nestabilnost* kognitivno-motoričkog sustava pri realizaciji BOP zadatka (N-BOP) je prosječna varijacija vremena uspješnog rješavanja BOP-zadataka i najčešće se mjeri standardnom devijacijom rezultata kognitivno-motoričkog sustava na nizu ekvivalentnih BOP-zadataka riješenih u zadanom vremenu: dakle, radi se o IIV-u BOP-rezultata čiji veći iznos ukazuje na veću nestabilnost kognitivno-motoričkog sustava pri realizaciji BOP-zadataka.
- *Izdržljivost ili otpornost* kognitivno-motoričkog sustava pri realizaciji BOP-zadatka (O-BOP) je pokazatelj koji mjeri koliko je osoba otporna na djelovanje nepovoljnih čimbenika – što unutarnjih kao što je umor, što vanjskih kao što su distraktorski podražaji. Operacionaliziran je pomoću dva pokazatelja koja mjere dva vida netočnog odgovaranja: otpornost na pogreške (OP-BOP) i otpornost na omaške (OO-BOP). Dobiven je iz omjera prosjeka rednog broja u kojem sudionik čini prve dvije pogreške (ili omaške) i (rednog broja) njegovog zadnje riješenog zadatka. Omjer može poprimiti vrijednost između ništice i vrijednosti malo iznad jedinice (okvirno od 0,05 do 1,1). Veći omjer upućuje na veću otpornost zato što veličina omjera korespondira s relativnom pozicijom učinjene pogreške ili omaške: prosječna pogreška/omaška učinjena bliže zadnje riješenom zadatku testa ishodi većim omjerom, odnosno, manji omjer je rezultat prosječne pogreške/omaške učinjene bliže početku testa. Dakle, što je osoba dalje stigla u zadacima bez učinjene pogreške ili omaške, smatra se kako je ona otpornija na djelovanje nepovoljnih čimbenika. Pogreške su bili slučajevi krivo precrtanih riječi, a omaške izostanak precrtavanja ciljnih riječi, zbog čega postoje dva indikatora otpornosti ili izdržljivosti BOP sustava.

Cilj i problemi

Cilj istraživanja je istražiti odnos nekoliko vidova perceptivne brzine, kao mjere BOP-a, s fluidnom inteligencijom i relevantnim dimenzijama velepetorog modela ličnosti, radi sveobuhvatnijeg sagledavanja teorijskog modela i uloge BOP-a. U svrhu ostvarenja navedenog cilja obrađeno je nekoliko problema.

1. Prvi problem preliminarno vrednuje valjanost tri vida perceptivne brzine, kao mjere BOP-a: prosječnu djelotvornost (PD-BOP), nestabilnost (N-BOP) i otpornost djelovanju nepovoljnih čimbenika (O-BOP). U okviru ovog problema testiraju se sljedeće hipoteze:

H1-1: PD-BOP je mjera prosječnog funkcioniranja kognitivno-motoričkog sustava angažiranog u rješavanju testa perceptivne brzine koja pokazuje optimalnu diskriminativnost te visoku izravnu i konstruktnu (konvergentnu i diskriminantnu) valjanost.

H1-2: N-BOP je mjera nestabilnosti funkcioniranja kognitivno-motoričkog sustava angažiranog u rješavanju testa perceptivne brzine koja pokazuje optimalnu diskriminativnost te visoku izravnu i konstruktnu (konvergentnu i diskriminantnu) valjanost.

H1-3: O-BOP je mjera otpornosti funkcioniranja kognitivno-motoričkog sustava angažiranog u rješavanju testa perceptivne brzine prema djelovanju nepovoljnih čimbenika koja pokazuje optimalnu diskriminativnost te visoku izravnu i konstruktnu (konvergentnu i diskriminantnu) valjanost.

H1-4: PD-BOP, N-BOP i O-BOP pokazuju statistički značajne zasebne doprinose predviđanju fluidne inteligencije.

2. Drugi problem analizira odnos tri vida perceptivne brzine, kao mjere BOP-a, s jednom mjerom fluidne inteligencije procijenjene testom D-2000. U okviru ovog problema testiraju se sljedeće hipoteze:

H2-1: PD-BOP u studentskoj populaciji pokazuje nisku do srednju pozitivnu povezanost s fluidnom inteligencijom.

H2-2: N-BOP u studentskoj populaciji pokazuje nisku do srednju negativnu povezanost s fluidnom inteligencijom.

H2-3: O-BOP u studentskoj populaciji pokazuje nisku pozitivnu povezanost s fluidnom inteligencijom.

3. Treći problem analizira odnos tri vida perceptivne brzine, kao mjere BOP-a, s tri osobine ličnosti relevantne za uspjeh u testu perceptivne brzine – intelektom, emocionalnom stabilnošću i savjesnošću. U okviru ovog problema testiraju se sljedeće hipoteze:

H3-1: PD-BOP u studentskoj populaciji pokazuje nisku pozitivnu povezanost s intelektom i emocionalnom stabilnošću, te nisku negativnu povezanost sa savjesnošću.

H3-2: N-BOP u studentskoj populaciji pokazuje nisku negativnu povezanost s intelektom i emocionalnom stabilnošću, te nisku pozitivnu povezanost sa savjesnošću.

H3-3: O-BOP u studentskoj populaciji pokazuje nisku pozitivnu povezanost s intelektom, emocionalnom stabilnošću i savjesnošću.

Metoda

Sudionici

U istraživanju je sudjelovalo 209 studenata dviju sastavnica Sveučilišta u Zagrebu, odnosno, dva studijska programa Fakulteta prometnih znanosti (FPZ-a) (cestovni promet i aeronautika), te tri studijska programa Hrvatskih studija (HS-a) (filozofija, komunikologija i psihologija). Broj sudionika s pojedinog studijskog programa prikazan je u *Tablici 1.*, pri čemu treba uzeti u obzir da zbog različitih tehničkih razloga ni u jednoj promatranoj varijabli nije izmjereno svih 209 sudionika (najviše ih je izmjereno na testu D-2000). Studenti FPZ-a činili su većinu uzorka sa 123 sudionika (58,85%), a ostatak uzorka, ukupno 87 sudionika (41,63%), bili su studenti HS-a. Pritom je uzorak prilično ravnomjeran glede njegove spolne strukture. Naime, među sudionicima je 107 muškaraca (51,20%) i 95 žena (45,50%) – za ostatak osoba (ukupno sedam osoba) nedostaje podatak o spolu.

Tablica 1. *Prikaz studijskih smjerova ispitanika*

	n	Postotak	Kumulativni postotak
Filozofija	11	5,26%	5,26%
Cestovni promet	97	46,41%	51,67%
Komunikologija	25	11,96%	63,64%
Aeronautika	25	11,96%	75,60%
Psihologija	51	24,40%	100,00%
Ukupno	209	100,00%	

Ovo istraživanje je provedeno u dva vala mjerenja koja su imala približno jednak broj sudionika. Prvi val uključivao je isključivo studente cestovnog prometa s FPZ-a (97 sudionika ili 46,20% uzorka), dok je drugi val sadržavao studente aeronautike s FPZ-a i studente tri programa HS-a (u drugom valu je sudjelovalo 112 osoba koji čine 53,30% uzorka).

Budući da su u ovom radu spojeni podaci iz dva vala mjerenja (prvenstveno radi veće statističke snage nalaza i populacijske valjanosti na studentskoj populaciji), postojala je potreba analize opravdanosti ujedinjavanja dva uzorka, a koja se temelji na razini usklađenosti niza pokazatelja među uzorcima. Prvo je testirana jednakost aritmetičkih sredina i homogenost varijanci varijabli, što je prikazano u Tablici P3. Priloga. Aritmetičke sredine varijabli dva uzorka razlikuju se kod svega 3 od 10 promatranih varijabli – D-2000 (t = -3,37, df = 200, p < 0,001), emocionalna stabilnost (t = 3,15, df = 197, p = 0,002) i intelekt (t = -3,05, df = 197, p < 0,001) – dok se varijance razlikuju samo kod 1 od 10 promatranih varijabli - PD-BOP (F = 9,8 , df_1 = 95 , df_2 = 96 p = 0,002).

Nadalje, iznos koeficijenta varijabilnosti bio je dosljedan među uzorcima, što je vidljivo iz Tablica P1. i P2. u Prilogu. Naime, iz tih tablica je zamjetno kako su sve varijable koje su imale optimalno ili neoptimalno raspršenje rezultata u prvom uzorku, zadržale svoj optimalan ili neoptimalan varijabilitet u drugom uzorku. Slično tome, većina varijabli (80%) koja je u prvom uzorku imala asimetričnu raspodjelu, imala je i u drugom uzorku asimetričnu raspodjelu, s iznimkom N-BOP (z_1 = 1,55 , z_2 = 4,67) i savjesnosti (z_1 = -1,57 , z_2 = -1,98). Osim toga, gotovo sve varijable (90%) čiji su rezultati bili normalno raspodijeljeni u prvom uzorku su bile normalno raspodijeljene i u drugom uzorku, s iznimkom PD-BOP (SWz_1 = 0,976 , df_1 = 88 , p_1 = 0,100 ; SWz_2 = 0,973 , df_2 = 93 , p_2 = 0,048), a što je primjetno iz Tablica P1. i P2. Priloga.

Iz rezultata analize dva uzorka (u Prilogu) uočljivo je kako ni u jednom uzorku nije bila prisutna strategija rješavanja „brzina na-uštrb točnosti“, što je razvidno iz korelacija između

ukupnog broja riješenih zadatka i ukupnog broja netočnosti (r_1 = -0,033, p > 0,5 ; r_{s1} = -0,078, p_1 > 0,5) (r_2 = 0,131, p_2 > 0,2; r_{s2} = 0,109, p_2 > 0,2).

Konačno, usporedbom korelacijskih matrica (prikazanih u Tablicama P4. i P5. Priloga), ostvaruje se dodatan uvid u stupanj usklađenosti rezultata dva uzorka. Matrice sadrže 45 korelacija i prva uočljiva razlika među uzorcima jest u broju značajnih koeficijenata (bilo Pearsonovih, bilo Spearmanovih). U prvom uzorku je dobiveno 21 statistički značajna korelacija, dok ih je u drugom dobiveno tek 7. Unatoč zamjetnoj razlici u broju značajnih korelacija, omjer linearnih i nelinearnih korelacija je sličan: u prvom uzorku su 14 od 21 značajne korelacije nelinearne (66% korelacija), a u drugom uzorku su 3 od 7 nelinearne (43% korelacija). Dodatna je sličnost i u strukturi nelinearnih korelacija jer, u prvom je uzorku većina nelinearnih korelacija (50% korelacija) uključivalo neku neprosječnu mjeru BOP-a (N-BOP, OP-BOP ili OO-BOP), dok sve tri nelinearne korelacije drugog uzorka uključuju neku neprosječnu mjeru BOP-a. Pored toga, primjetne su znatne sličnosti uzoraka u pogledu međusobnih korelacija pokazatelja dinamike funkcioniranja BOP sustava.

Vidljive su i određene dosljednosti u smjerovima i iznosima korelacija značajnih u oba uzorka, a što je vidljivo iz Tablica P4. i P5. Priloga. Kao prvo, šest statistički značajnih korelacija dobiveno je među istim mjerama u oba uzorka. Pet ih je uključivalo neku mjeru BOP-a, a jedan odnos ekstraverzije i emocionalne stabilnosti. Smjer svih značajnih korelacija bio je jednak među uzorcima, a iznosi su bili sličnih vrijednosti. Naime, iznosi su bili (gotovo) jednaki u korelaciji N-BOP-a i OP-BOP-a, OP-BOP-a i OO-BOP-a, te ekstraverzije i emocionalne stabilnosti. S druge strane, najveća razlika koeficijenta korelacije među uzorcima iznosila je 0,2 (za odnos g_f i PD-BOP-a), a najmanja 0,036 (za odnos PD-BOP-a i OP-BOP-a). Dakle, kod statistički značajnih korelacija veća je sličnost uočena u smjeru povezanosti, nego li u iznosima.

Kod statistički neznačajnih korelacija proizlazi dodatna sličnost dva uzorka: 23 koeficijenata bila su statistički jednaka nuli u oba uzorka.

Zbirno gledajući, uz šest istovjetnih značajnih korelacija oba uzorka i 23 koje su neznačajne, sveukupno 29 od 45 korelacija - ili 64% - su bile istovjetne u dva promatrana uzorka. Među 16 korelacija koja su se javila u jednom, ali ne i u drugom uzorku, šest su se odnosile na međusobne korelacije osobina ličnosti, pet na korelacije osobina ličnosti i pokazatelje BOP-a, tri na korelaciji neprosječnih pokazatelja BOP-a i g_f i dvije na međusobnoj korelaciji pokazatelja BOP-a.

Zaključno, velika većina usporedbi mjera centralne tendencije, varijabiliteta i međusobnih povezanosti konstrukata procijenjenih u istraživanju ukazala je na visoku usklađenost tih mjera u dva uzorka te jasno sugerira opravdanost objedinjavanja rezultata u jedan uzorak. Budući da su isti instrumenti, primijenjeni u standardiziranim uvjetima i na socio-demografski sličnim uzorcima, velika sličnost među navedenim mjerama govori i u prilog psihometrijskoj valjanosti instrumenata, kao i metodološkoj valjanosti istraživanja.

Instrumenti

D-2000

Test D-2000 je neverbalni test opće intelektualne sposobnosti koji je nastao temeljem Testa D-48 i Testa D-70 kao revidirana inačica tih testova, a koji – sukladno suvremenim diferencijalnim modelima inteligencije – u najvećoj mjeri procjenjuje g_f. Iako je sličan ranijim inačicama, ipak je primjereniji visokoobrazovanim skupinama. Sastoji se od 40 zadataka u obliku crteža domina poslaganih po određenom načelu, naime, po spacijalnom, numeričkom, miješanom i aritmetičkom načelu (Ćosić i Matešić, 2009), a zadaci zahtijevaju da se jedan, prazan crtež, uvidom u načelo po kojem se mijenjaju domino pločice, popuni na ispravan način, odnosno, određivanjem točnog broja točkica u gornjem i donjem dijelu praznog domina. Krajnji rezultat ispitanika jest zbroj svih (točno odgovorenih) odgovora, tako da je najmanji mogući iznos 0, a najveći mogući iznos 40. Težina čestica raste progresivno i donekle pravilno u cijelom testu.

Ćosić i Matešić (2009) navode kako unutarnja pouzdanost tipa alfa testa iznosi (α_c = 0,87) i da pouzdanost testa narušavaju zadatak 18, 35, 36, 38 i 39. Na uzorku ovog istraživanja je dobiven nešto niži, ali i dalje zadovoljavajući iznos unutarnje pouzdanosti od 0,81 koji je ostao nepromijenjenog iznosa kada su izbačeni (gore ispisani) problematični zadaci.

Faktorska analiza prvog reda u radu Ćosić i Matešić (2009) rezultirala je trima faktorima koji objašnjavaju 27,73% varijance, što je očekivano s obzirom na ranije nalaze (Priručnik za primjenu Testa D-2000, 2009) i na sličnost s testom D-48 koji pokazuje istu strukturu (Momirović i Kovačević, 1970). Ta tri faktora su u modelu Momirovića i Kovačevića (1970) prepoznata kao faktor edukcije, faktor simboličkog rezoniranja i faktor perceptivnog rezoniranja, a u svom radu pokazuju da zajedno čine generalni kognitivni faktor. Provedbom faktorske analize drugog reda su Ćosić i Matešić (2009) dobili sličan nalaz za D-2000, odnosno,

dobili su jedan faktor koji objašnjava 52,03% varijance, zaključujući u skladu s rezultatom i očekivanjima da se u rješavanju testa očituje jedan generalni kognitivni faktor.
Hrvatsku standardizaciju proveli su Matešić i suradnici početkom 2009. (Priručnik za primjenu Testa D-2000, 2009).

IPIP50

Kratka inačica upitnika velepetorih osobina ličnosti IPIP 50 (International Personality Item Pool) korištena je kao mjera pet osobina ličnosti sudionika. Upitnik sadrži deset čestica za svaku velepetoru dimenziju (ekstraverziju, ugodnost, savjesnost, emocionalnu stabilnost i intelekt), a ocjenjivane su Likertovom skalom od 1 (u potpunosti se ne slažem), preko 3 (niti se slažem, niti se ne slažem) do 5 (u potpunosti se slažem). Drugim riječima, ispitanici izražavaju stupanj slaganja s jasno usmjerenom tvrdnjom/česticom kao što je, primjerice, „Lako podliježem stresu“. Upitnik je stvoren iz prijevoda Goldbergove odnosno američke inačice velepetorog upitnika ličnosti (Mlačić i Goldberg, 2007), a nakon uspješnog prijevoda upitnika provedena su mjerenja samoprocjenom ličnosti i procjenom drugih, bliskih osoba. Mlačić i Golberg (2007) izvijestili su kako je hrvatska inačica međukulturalno valjana, a isto tako su utvrdili umjereno visoku unutarnju pouzdanost iskazanu Cronbach alfom (prosječna vrijednost samoprocjene i procjene drugih iznosila je $\alpha_c = 0,88$). Sličan nalaz dobiven je u istraživanju na uzorku 706 adolescenata iz Zagreba i Požege (prosječan iznos alfa pouzdanosti samoprocjene ličnosti bila je $\alpha_c = 0,82$, a za procjenu drugih, u ovom slučaju roditelja, Cronbachov alfa iznosio je $\alpha_c = 0,84$) (Mlačić, Milas i Kratohvil, 2007). Na uzorku ovog istraživanja, koja je po socio-demografskim karakteristikama slična gore opisanim uzorcima, prvenstveno uzorku Mlačića i Goldberga (2007), provedena je analiza unutarnje pouzdanosti (Tablica 2.) i dobivena je prosječna vrijednost od ($\alpha_c = 0,77$), što predstavlja nešto niži rezultat nego li je dobiven u gore opisanim radovima. Dobivena niža vrijednost Cronbachovog alfa može se objasniti analizom unutarnje pouzdanosti mjere ugodnosti s obzirom na val mjerenja, tj., s obzirom na to iz kojeg visokog učilišta sudionik dolazi. Sudionici prvog vala mjerenja (89 studenata s FPZ-a) pokazuju izrazito nisku (tj. nepostojeću) pouzdanost u odgovorima ($\alpha_c = 0,53$), za razliku od sudionika drugog vala mjerenja (105 studenata uglavnom s HS-a) koji pokazuju zadovoljavajuće visoku vrijednost istog statistika ($\alpha_c = 0,84$). Naime, studentice HS-a vjerojatno su više naviknute i motiviranije ispuniti upitnik od studenata FPZ-a. Dodatno objašnjenje snižene pouzdanosti (poglavito kod sudionika s FPZ-a) može se tražiti u suženom varijabilitetu rezultata jer se radi

o selekcioniranoj populaciji studenata, a Cronbach alfa temelji se na prosječnom kovariranju rezultata svih čestica.

Nadalje, velepetora (faktorska) struktura upitnika potvrđena je (samoprocjenom) na uzorku 426 studentica i 93 studenta Sveučilišta u Zagrebu prosječne dobi od 19,5 (±1,9) u istraživanju Mlačića i Goldberga (2007), ali i u istraživanju na 706 zagrebačkih i požeških srednjoškolaca, tj. adolescenata, odnosno, 383 žena i 323 muškaraca prosječne dobi od 16,9 (±1,1) i procjene jednog od njihovih roditelja, uglavnom majki (n = 459), ali i očeva (n = 127) sveukupno prosječne dobi od 44,6 (±5,4) godina (Mlačić i sur., 2007). Unutar tih istraživanja očituje se dosljednost (velepetore) faktorske strukture upitnika s obzirom na to je li riječ o samoprocjeni ili procjeni drugih, a isto tako postoji dosljednost nalaza faktorske analize među tim istraživanjima.

Tablica 2. *Prikaz alfa pouzdanosti za IPIP 50*

	Cronbachov alfa	Broj čestica
Ekstraverzija	0,85	10
Ugodnost	0,69	10
Savjesnost	0,83	10
Emocionalna stabilnost	0,88	10
Intelekt	0,71	10
Mdn (C)	0,77	

KS2-2

Test kognitivnih sposobnosti 2 ili KS2-2 predstavlja neutralnu komponentu obojene verzije papir-olovka Stroop testa koja se često naziva „verzija u blokovima“ (Ludwig i sur., 2010, prema Žebec i sur., 2017). Test čini 448 riječi od kojih su polovica riječ *crveno* i polovica riječ *zeleno*, a sve riječi su napisane malim tiskanim slovima i ispisane u crnoj boji. Diljem testa, odnosno kroz sve retke testa, sadržaj i prostorni raspored riječi nasumično variraju. Zadatak sudionika sastoji se u precrtavanju (s lijeva na desno i s jednom kosom crtom) što više ciljnih riječi, tj., riječi *zeleno*, prateći raspored redaka (od vrha stranice prema dnu) i s lijevog prema desnom dijelu stranice. Rješavanje testa ograničeno je na 60 sekundi zbog čega KS2-2 pripada testovima brzine.

Žebec i sur. (2017) prikazali su metrijska svojstva testa koja su zadovoljavajuća. Naime, objektivnost je zadovoljena standardizacijom uvjeta skupnog mjerenja, gdje jasno postoje točni i netočni odgovori, odnosno objektivan način kodiranja rezultata.

Nadalje, Žebec i sur. (2017) navode da, iako je varijabilitet mjere sužen (*CV* = 12,29% , *min* = 72 , *max* = 148), može se govoriti o dobroj osjetljivosti testa jer postoji normalna raspodjela rezultata (*KSz* = 0.589, p=0.879), a koja ukazuje i na konstruktnu valjanost testa. Usporedni rezultati na uzorku ovog diplomskog rada pokazuju slične osobine, naime, dobiveni CV ima nešto optimalniji varijabilitet (*CV* = 15,29% , *min* = 51 , *max* = 138), a dobivena je normalna raspodjela rezultata (*SWz* = 0,994 , *df* = 181, *p* = 0,682).

Pouzdanost testa je mjerena test-retest metodom pouzdanosti i rezultati pokazuju dobru pouzdanost testa r_{xx} = 0,795 (Žebec i sur., 2017). Osim toga, u radu Žebeca i sur. (2017) je isključena prisutnost strategije „brzina na uštrb točnosti" tako da je provjerena korelacija broja točno precrtanih riječi i broja netočnih odgovora, koja je u njihovom radu bila neznačajna (*r* = - 0,068), a i u ovom diplomskom radu je bila neznačajna (*r* = 0,046 , *p* = 0,523 ; r_s = 0,0 , *p* = 0,997).

Test KS2-2 je mjera perceptivne brzine (Žebec i sur., 2017), a u ovom radu predstavlja operacionalizaciju konstrukta BOP. Osim prosječne mjere kognitivnog sustava izračunate su i dvije neprosječne mjere u svrhu sveobuhvatnijeg prikaza dinamičkog sustava brzine obrade podataka. Budući da je među ključnim ciljevima ovog diplomskog rada provjera valjanosti tri vida perceptivne brzine, podrobna analiza ovih nalaza bit će opisana u rezultatima, raspravi i zaključku.

Tri pokazatelja dinamike funkcioniranja kognitivno-motoričkog sustava mjerene perceptivne brzine su: prosječna djelotvornost (PD-BOP), nestabilnost (N-BOP), i dvije mjere otpornosti na djelovanje nepovoljnih čimbenika (O-BOP) – otpornost na pogreške (OP-BOP) i otpornost na omaške (OO-BOP). Matematički izračun odnosno definicija ovih pokazatelja jest sljedeća:

1. PD-BOP = *n*(točno precrtanih ciljnih riječi)

2. N-BOP = SQRT {[Σ(odgovor u prvom zadataku^2 + odgovor u drugom zadatku^2 + ... + odgovor u četrdesetom zadatku^2) – Σ(odgovor u prvom zadatku + odgovor u drugom zadatku + ... + odgovor u četrdesetom zadatku)^2 / redni broj zadnje riješenog zadatka] / *N* – 1}

alternativni prikaz:

$$\text{N-BOP} = \sqrt{\frac{\sum_{i=1}^{N} x_i^2 - \frac{(\sum_{i=1}^{n} x_i)^2}{N}}{N-1}}$$ (x je rezultat na svakom zadatku, od 1. do 40.)

3. O-BOP = [(redni broj zadatka u kojem se javlja prva pogreška/omaška + redni broj zadatka kojem se javlja druga pogreška/omaška) / 2] / redni broj zadnje riješenog zadatka

Postupak

Svi podaci prikupljeni su u standardnim uvjetima skupnog ispitivanja u prostorijama FPZ-a i HS-a. Prvi val mjerenja proveden u travnju i svibnju 2016. godine, a drugi val u listopadu i prosincu 2018. godine. Međutim, uvjeti mjerenja su u oba slučaja bili gotovo istovjetni, posebice u smislu fizičkih uvjeta provođenja testiranja te preciznih i standardiziranih uputa za ispitivanje. Sudionici su na stolu imali isključivo olovku za rješavanje zadataka i omotnicu u kojoj su spremani instrumenti, te je svima osigurano dovoljno prostora kako bi neometano rješavali zadatke. Objašnjeno im je kako je svrha ispitivanja primarno istraživačka i obrazovna (u drugom valu spomenuta je i izrada diplomskog rada) i da će uvid u rezultate imati isključivo istraživači te student/sudionik koji zatraži uvid samo u svoje rezultate. Dodatno je pojašnjeno kako se podaci neće koristiti u neznanstvene svrhe, da im je anonimnost zajamčena (u drugom valu mjerenja pojašnjen je i jedinstven način šifriranja identiteta sudionika) i da, ukoliko žele, mogu odustati od ispitivanja u bilo kojem trenutku. S obzirom na to da se radi o korelacijskom istraživanju s nacrtom poprečnog presjeka, nastojalo se u istoj vremenskoj točki izmjeriti vrijednosti na sva tri korištena instrumenta (jedina iznimka bili su studenti psihologije, kojima se – iz tehničkih razloga – D-2000 i KS2-2 primijenio s tjedan dana razmaka) po sljedećem redoslijedu: D-2000, KS2-2, IPIP 50. Svim skupinama je dana jednaka, standardizirana uputa rješavanja testa D-2000, s primjerom i vremenom za pojašnjenje eventualnih nejasnoća. Testiranje je krenulo tek kada je osigurano razumijevanje upute i kada je potvrđena dobrovoljnost sudjelovanja u istraživanju, a vrijeme rješavanja testa D-2000 ograničeno je na 20 minuta, što je mjereno zapornim satom. Na kraju tog testiranja dan je nalog pospremanja svih materijala testa u omotnicu i vađenja testa KS2-2 za koji je pročitana standardizirana uputa rješavanja s primjerom i vremenom za upit o eventualnim nejasnoćama rješavanja zadataka. Rješavanje testa krenulo je nakon što su svi sudionici razumjeli način

rješavanja zadataka, a vrijeme rješavanja je ograničeno na 60 sekundi (također mjereno zapornim satom). Po završetku testa KS2-2 je isti spremljen u omotnicu. Kada su svi sudionici izvadili upitnik ličnosti IPIP 50, dana im je standardizirana uputa rješavanja upitnika i nakon što je utvrđeno potpuno razumijevanje načina odgovaranja, sudionici su krenuli ispunjavati taj upitnik bez vremenskog ograničenja, ali s napomenom da bi zadatak trebao biti završen unutar 10 minuta. Nakon što su sudionici ispunili upitnik ličnosti i pospremili ga u omotnicu, istraživač je pokupio sve omotnice. Premda se u okviru standardiziranog postupka osigurala tišina među sudionicima ispitivanja, kao eventualnu prijetnju kontrole fizičkih čimbenika ispitivanja može se navesti povremena i rijetka buka koja je dolazila izvan prostorija za ispitivanje.

Rezultati

U Metodi je detaljno opisano kako su rezultati ovog rada dobiveni na dva nezavisna uzorka studenata Sveučilišta u Zagrebu, ispitana sa zamjetnim vremenskim razmakom, a koji su slični po socio-demografskim osobinama. Iz već opisane sličnosti niza deskriptivnih statistika i međusobnih korelacija varijabli među uzorcima izveden je zaključak o: valjanosti istraživačke metodologije, stabilnosti nalaza između uzoraka i opravdanosti uopćavanja na populaciju studenata FPZ-a i HS-a, te opravdanosti spajanja rezultata dva uzorka u jedan, objedinjen uzorak. Slijedi statistički analiza pojedinih problema istraživanja na objedinjenom uzorku.

Tablica 3. *Deskriptivna statistika varijabli istraživanja*

		gf	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
N	Valjani	202	193	193	199	199	199	199	199	199	199
	Nedostaju	8	17	17	11	11	11	11	11	11	11
	M	17,4	99,2	0,3	1,0	0,9	3,4	3,9	3,6	3,2	3,7
	SD	5,19	15,16	0,24	0,22	0,24	0,68	0,61	0,64	0,76	0,48
	Mdn (C)	18,0	98,0	0,2	1,0	1,0	3,5	3,9	3,7	3,2	3,7
	iq	7,00	21,50	0,41	0,01	0,08	0,90	0,60	0,90	1,10	0,70
	min	4,00	51,00	0,0	0,1	0,07	1,60	0,20	1,70	1,20	2,20
	max	31,00	138,00	1,3	1,08	1,06	5,00	5,00	5,00	4,90	4,80
	CV	29,78	15,29	93,66	23,08	25,95	19,85	15,80	17,64	23,68	13,05
	z	-1,28	0,05	4,60	-14,76	-12,21	-1,16	-8,02	-2,63	-1,30	-0,58
	Statistik	0,989	0,994	0,884	0,484	0,611	0,991	0,926	0,980	0,986	0,993
SW	*df*	202	193	193	199	199	199	199	199	199	199
	p	0,111	0,647	0,001	0,001	0,001	0,222	0,001	0,007	0,054	0,409

Napomena: g_f je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt, z je mjera asimetrije raspodjele i SW označava Shapiro-Wilk statistike

Broj sudionika kreće se od 193 do 202 s medijanom u iznosu od 199. Dakle, uzorak je dostatan za izračun većine statistika i korelacija.

Obrade rezultata vezane uz 1. problem

Prvi problem istražuje valjanost tri vida perceptivne brzine, odnosno pripadnog kognitivno-motoričkog sustava, i raščlanjen je na četiri hipoteze. Nalazi koji se vežu uz provjeravanje prve tri hipoteze (optimalna diskriminativnost, te visoka izravna i konstruktna valjanost PD-BOP, N-BOP i O-BOP) su sljedeći.

Diskriminativnost PD-BOP-a je dobra, iako nije optimalna jer koeficijent varijabilnost (*CV*) PD-BOP-a izlazi iz optimalnog raspona (*20-30*%), ukazujući na nešto užu raspodjelu od optimalne, ali su rezultati te BOP-mjere normalno raspodijeljeni ($SWp > 0{,}05$). Na dobru diskriminativnost upućuje i odsustvo učinka stropa i poda (vidi minimalnu i maksimalnu vrijednost u Tablici 3.).

Psihometrijska osjetljivost preostala dva pokazatelja dinamike BOP je prilično narušena, što pogotovo vrijedi za N-BOP. To se vidi iz njegova izrazito visokog *CV*-a koji dovodi u pitanje reprezentativnost pripadne mjere centralne tendencije, te iz značajnog iznosa *SWz* statistika ($p = 0{,}001$) koji ukazuje na izrazito pozitivno asimetričnu raspodjelu rezultata. Budući da je minimalni iznos N-BOP-a nula i da je prosjek varijable blizak nuli, to znači da je kod većine sudionika dobiven vrlo mali intraindividualni varijabilitet ili je on u potpunosti izostao – što je pravi razlog visokom *CV*-u te varijable IIV-a, premda je njegova diskriminativnost poprilično narušena te varijabla pokazuje jasan učinak poda. Dvije mjere O-BOP-a su ipak imale *CV* unutar optimalnog raspona, ali su uz to imale izrazito negativno asimetrične raspodjele (Tablica 3.) i jasno ostvaren učinak stropa. Naime, prosjek mjera O-BOP-a je gotovo jednak maksimalnom iznosu (*gotovo 1,1*) što znači da je većina sudionika bila izrazito otporna na pogreške i omaške, odnosno, većina sudionika tijekom cijelog testa, ako uopće jest učinila pogrešku/omašku, tu pogrešku/omašku čini pred kraj testa.

U okviru analiza potrebnih za odgovor na prve tri hipoteze podaci Tablice 3. dodatno služe za ispitivanje pretpostavki korelacijskih izračuna potrebnih za procjenu konvergentne i diskriminantne valjanosti, te je na ovom mjestu nužno i njih komentirati. Svaka varijabla mjerena je na intervalnoj ili omjernoj skali, pri čemu su rezultati polovice varijabli bili

normalno raspodijeljeni, te su od normaliteta odstupale neprosječne mjere BOP-a, kao i osobine U i S. Asimetričnost ne bi smjela predstavljati značajan problem računanju korelacije jer se sve značajne asimetrije odnose na negativnu asimetriju, osim raspodjele N-BOP-a (koja je pozitivno asimetrična) – zbog čega će korelacije N-BOPa s varijablama negativno asimetričnih raspodjela biti podcijenjena. Kod četiri varijable (PD-BOP, U, S te I) je *CV* – a time i varijabilitet – sužen, zbog čega će pripadne korelacije teško postizati maksimalne iznose. Međutim, zbog umjetno povećanog *CV*-a varijable N-BOP i ona će također imati podcijenjene korelacije sa svim ostalim varijablama.

Konstruktna valjanost tri promatrana indikatora dinamike funkcioniranja BOP-sustava vidljiva je iz pripadnih međusobnih korelacija za koje je očekivano da su niske ili neznačajne (diskriminantna valjanost), te iz njihovih korelacija s drugim varijablama s kojima je očekivana značajna korelacija (vid konvergentne valjanosti), a to su prvenstveno fluidna inteligencija, te, u manjoj mjeri, osobine ličnosti I, ES i S. S osobinama E i U ne očekuju se korelacije tri pokazatelja BOP-a te eventualna potvrda nultih korelacija također odražava njihovu diskriminantnu valjanost.

Prije navođenja korelacijskih tablica provjerena je eventualna prisutnost strategije rješavanja testa „brzina na-uštrb točnosti“ ili *speed-accuracy trade-off* kod ispitanih sudionika. Prisutnost te strategije provjerava se izračunom korelacije između ukupnog broja riješenih zadataka i ukupnog broja netočnosti: ako je ta korelacija statistički značajna i pozitivna, onda postoji ta strategija. Rezultati računanja Pearson (r) i Spearman (r_s) koeficijenata korelacije (r = 0,046, p = 0,523; r_s = 0,0 , p = 0,997) jasno pokazuju kako ta strategija nije bila prisutna.

Tablica 4. *Pearsonovi i Spearmanovi koeficijenti korelacije varijabli u istraživanju*

		g_f	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
g_f	Pearson	1	0,319**	-0,124*	-0,053	0,084	-0,039	0,055	-0,084	0,029	0,135
	Spearman		0,268**	-0,114	-0,205**	0,145*	0,001	0,002	-0,075	0,018	0,131
	N	202	191	191	197	197	192	192	192	192	192
PD-BOP	Pearson		1	-0,12	-0,103	-0,297**	0,078	0,149*	0,079	0,191**	0,119
	Spearman			-0,176*	-0,696**	-0,242**	0,063	0,122	0,074	0,172*	0,107
	N		193	192	193	193	183	183	183	183	183
N-BOP	Pearson			1	-0,065	-0,284**	-0,047	-0,059	0,072	-0,085	-0,153*
	Spearman				0,033	-0,657**	-0,054	-0,096	0,056	-0,104	-0,198**
	N			193	193	193	183	183	183	183	183
OP-BOP	Pearson				1	0,04	-0,068	-0,025	0,012	0,027	0,051
	Spearman					0,207**	-0,128	-0,099	0,011	-0,059	-0,07

	N	199	199	189	189	189	189	189
OO-BOP	Pearson		1	0,006	-0,081	-0,072	-0,042	0,03
	Spearman			0,019	0,005	-0,102	-0,04	0,135
	N		199	189	189	189	189	189
E	Pearson			1	0,146*	-0,02	0,335**	0,212**
	Spearman				0,113	-0,012	0,310**	0,240**
	N			199	199	199	199	199
U	Pearson				1	0,126	0,02	0,109
	Spearman					0,116	-0,028	0,207**
	N				199	199	199	199
S	Pearson					1	0,172*	0,08
	Spearman						0,148*	0,087
	N					199	199	199
ES	Pearson						1	0,082
	Spearman							0,09
	N						199	199

Napomena: ** $p < 0,01$, * $p < 0,05$, *g_f je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP su mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt*

PD-BOP pokazuje visoku diskriminantnu valjanost u odnosu na N-BOP, OP-BOP i OO-BOP, te sve osobine ličnosti, premda su neke korelacije očekivano značajne i uglavnom logičnog smjera. S tri ne-prosječne mjere BOP-a dijeli 3% (N-BOP), 8,8% (OO-BOP) te 48% (OP-BOP, izrazito nelinearno) zajedničke varijance, premda bi zbog gore navedenih osobitosti N-BOP-raspodjele pripadna korelacija trebala biti nešto veća. Ti koeficijenti determinacije uglavnom govore o tome kako različiti čimbenici određuju PD-BOP u odnosu na ostale neprosječne mjere premda, po svojoj definiciji, PD-BOP uključuje sve njih na određeni način. Smjer povezanosti PD-BOP-a i N-BOP-a ukazuje kako osobe s višom prosječnom djelotvornošću BOP-sustava donekle pokazuju nižu nestabilnost tog sustava. No, smjer povezanosti PD-BOP-a s OO-BOP-om, a posebice OP-BOP-om, čini se neočekivan: osobe višom prosječnom djelotvornošću BOP-sustava uglavnom pokazuju nižu otpornost tog sustava na djelovanje nepovoljnih čimbenika jer se omaške i pogreške kod njih uglavnom ranije javljaju u testu. Diskriminantna valjanost PD-BOP-a u odnosu na osobine ličnosti je vrlo visoka jer PD-BOP dijeli 0% zajedničke varijance s E i 2% s U.

Na konvergentnu valjanost PD-BOP-a ukazuje i blaga pozitivna povezanost s D-2000 (mjera g_f) koja upućuje na očekivanih 10% zajedničkih čimbenika, te blaga pozitivna povezanost s emocionalnom stabilnošću (s kojom dijeli 4% varijance) koja govori kako osobe višom

prosječnom djelotvornošću BOP-sustava u prosjeku pokazuju blago povećanu emocionalnu stabilnost. Dio konvergentne valjanosti vezan za nisku negativnu korelaciju s intelektom nije potvrđen.

N-BOP također pokazuje uglavnom visoku diskriminantnu valjanost u odnosu na ostale pokazatelje dinamike funkcioniranja BOP-sustava (jedino s OO-BOP-om, na nelinearan način, dijeli 43% varijance, a s preostale dvije mjere taj postotak ne prelazi 3%), koja je još veća u odnosu na osobine ličnosti (korelacije s E i U iznose 0). Pri tome treba uzeti u obzir da je takav ishod dijelom posljedica i suženog varijabiliteta te suprotne asimetrije N-BOP-a u odnosu na O-BOP, U i E. Smjer značajnih povezanosti je očekivan, isto kao i kod neznačajnih tendencija.

Na osrednju konvergentnu valjanost N-BOP-a ukazuje vrlo blaga pozitivna povezanost s mjerom g_f koja upućuje na 2% zajedničkih čimbenika: očekivanih s obzirom na obilježja raspodjele N-BOP-a. Odnos N-BOP-a s osobinama S i ES nije doprinjeo konvergentnoj valjanosti, ali donekle jest odnosom s intelektom (s kojim je pokazao očekivanu nisku i negativnu korelaciju).

Korelacije OP-BOP-a i OO-BOP-a (međusobne i s ostalim varijablama) pokazuju nekoliko zanimljivih osobina. Prvo, one su dominantno nelinearne (jer je u većini slučajeva Spearmanov koeficijent veći od Pearsonovog) i to ih izdvaja od ostalih promatranih varijabli. Drugo, u pogledu odnosa s ostalim pokazateljima dinamike funkcioniranja BOP-sustava, OP-BOP jedino s PD-BOP-om dijeli značajniji postotak varijance, a OO-BOP s N-BOP-om: što dokazuje uglavnom visoku diskriminantnu valjanost. Ta valjanost još je viša u odnosu na osobine ličnosti jer OP-BOP i OO-BOP ne pokazuju ni jednu značajnu povezanost s promatranim osobinama. Treće, niske i nekonzistentne (premda značajne) nelinearne korelacije s g_f upućuju na slabu konvergentnu valjanost OP-BOP-a i OO-BOP-a, premda taj nalaz treba oprezno razmotriti zbog nedostatne literature o odnosu ovih varijabli i g_f.

Kako bi se do kraja ispitao prvi problem rada testirana je četvrta hipoteza o zasebnim doprinosima pojedinih pokazatelja BOP-a predviđanju fluidne inteligencije pomoću linearne regresijske analize. Linearna regresijska analiza je prvo provedena pomoću metode *Enter* u tri bloka: u prvi blok je ušao PD-BOP, u drugi N-BOP, a u treći su ušli OP-BOP i OO-BOP.

Tablica 5. *Zasebni doprinosi pokazatelja BOP-a u predviđanju fluidne inteligencije – metoda Enter*

Model	Prediktor	β	*t*	*p*	R^2	R^2_{kor}	$F(R^2)$	ΔR^2	$F(\Delta R^2)$
1.	PD-BOP	0,308	4,44	0,001	0,095	0,09	19,702**	0,095	19,702**
2.	PD-BOP	0,298	4,27	0,001	0,102	0,092	10,616**	0,007	1,48

	N-BOP	-0,085	-1,22	0,23					
3.	PD-BOP	0,347	4,73	0,001	0,127	0,109	6,754**	0,025	2,699
	N-BOP	-0,028	-0,38	0,727					
	OP-BOP	-0,029	-0,42	0,672					
	OO-BOP	0,174	2,29	0,023					

*Napomena: ** p < 0.01, * p < 0.05 , PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP su mjere otpornosti (pogreškama i omaškama) BOP-a*

Prvi blok dao je najznačajniji doprinos predviđanju fluidne inteligencije (β = 0,308 , t = 4,44 , p < 0,001), a u trećem bloku se to predviđanje povećalo za dodatnih 2,5% (korigirani R^2), pri čemu je OO-BOP bio drugi značajni prediktor g_f (β = 0,174 , t = 2,29 , p = 0,023) . Dakle, N-BOP i OP-BOP nisu dali zaseban doprinos predviđanju g_f (Tablica 3.).

Slično se može vidjeti i iz *Stepwise* metode u istim blokovima iz Tablice 5., koja je izbacila N-BOP u drugom koraku i OP-BOP u trećem koraku, ostavivši samo dva značajna prediktora.

Tablica D4. *Zasebni doprinosi pokazatelja BOP-a u predviđanju fluidne inteligencije – metoda Stepwise*

Model	Prediktor	β	t	p	R^2	R^2_{kor}	$F(R^2)$	ΔR^2	$F(\Delta R^2)$
1.	PD-BOP	0,308	4,439	0,001	0,095	0,09	19,702**	0,095	19,701**
2.	PD-BOP	0,356	5,025	0,001	0,126	0,117	13,480**	0,031	6,664*
	OO-BOP	0,183	2,582	0,011					

*Napomena: ** p < 0.01, * p < 0.05 , PD-BOP je prosječna djelotvornost BOP-a, OO-BOP je mjera otpornosti omaškama BOP-a*

Prvi model metode *Stepwise* predviđa nešto manje od 10% varijance g_f, a drugi objašnjava dodatnih 3% varijance g_f.

Zanimljivo je istaknuti kako je mjera g_f zapravo pokazala najvišu (premda nisku i nelinearnu) povezanost s OP-BOP-om (-0,205*) koja u regresijskoj analizi nije generirala OP-BOP kao značajni prediktor: najvjerojatnije jer linearni regresijski model ne prepoznaje nelinearne odnose. Dodatno, ni značajna, premda niska povezanost g_f i N-BOP-a nije generirala

tu varijablu u značajni prediktor, najvjerojatnije zbog relativno visoke nelinearne korelacije N-BOP-a i OO-BOP-a.

Obrade rezultata vezane uz 2. problem

Iako su već kratko komentirane korelacije g_f s PD-BOP, N-BOP, OP-BOP i OO-BOP-om pod vidom konvergentne valjanosti četiri pokazatelja dinamike funkcioniranja BOP-sustava, u okviru drugog problema rada sustavno se analiziraju isti nalazi po pripadnim hipotezama.

Kao prvo, korelacija g_f s PD-BOP-om prikazana u Tablici 4. ukazuje na značajnu, linearnu, pozitivnu i uglavnom nisku povezanost (s 10% zajedničke varijance), za koju bi se moglo očekivati da u ne-selekcioniranoj populaciji bude čak i nešto viša.

Korelacija g_f s N-BOP iz Tablici 4. upućuje na to da se radi o značajnoj, linearnoj, negativnoj i vrlo niskoj povezanosti (s 1,5% zajedničke varijance), međutim, ona bi mogla biti osjetno viša u ne-selekcioniranoj populaciji te u slučaju normalnije raspodjele N-BOP varijable.

Zadnje analizirani podaci vezani uz drugi problem su korelacije g_f s OP-BOP-om i OO-BOP-om iz Tablice 4.. One najprije ukazuju na prisustvo značajne, nelinearne i niske korelacije koja nema konzistentan smjer – ovisno o tome promatra li se pojavljivanje pogreške, ili omaške u BOP-testu. Odnos g_f s OP-BOP-om je negativan (kod inteligentnijih pojedinaca se pogreške – ako se uopće pojave – jave u ranijem dijelu testa), dok je odnos g_f s OO-BOP-om pozitivan (kod inteligentnijih pojedinaca se omaške – ako se jave – pojave u kasnijem dijelu testa). Budući da se na zasebnim uzorcima ova suprotna povezanost g_f s OP-BOP-om i OO-BOP-om sustavno pojavljuje (u drugom uzorku na razini neznačajne tendencije, vidi Tablice P3. i P4. Priloga), opravdano je razmišljati o tome kako OP-BOP i OO-BOP ne predstavljaju istu mjeru O-BOP konstrukta, već dvije različite facete toga konstrukta.

Obrade rezultata vezane uz 3. problem

U okviru trećeg problema rada sustavno se analiziraju korelacije osobina ličnosti s PD-BOP, N-BOP, OP-BOP i OO-BOP-om po pripadnim hipotezama, iako su u okviru istraživanja

konvergentne i diskriminantne valjanosti indikatora dinamike funkcioniranja BOP-sustava ti isti nalazi već kratko komentirani.

Za početak, korelacije PD-BOP-a iz Tablice 4. ukazuju na to da u studentskoj populaciji prosječna djelotvornost kognitivno-motoričkog sustava u osnovi rješavanja BOP-testa ne pokazuje povezanosti sa S i I, ali pokazuje značajnu, linearnu, pozitivnu i nisku povezanost s ES, koja objašnjava svega 4% zajedničkih čimbenika na očekivani način: osobe koje pokazuju višu PD-BOP, u prosjeku pokazuju nešto višu ES. No, suženi varijabiliteti PD-BOP-a i većine osobina ličnosti ograničavaju dobivanje viših korelacija; kod manje selekcionirane populacije od studentske se mogu (eventualno) očekivati više korelacije.

Zatim je iz Tablice 4. vidljivo kako korelacije N-BOP-a upućuju na to da u studentskoj populaciji nestabilnost kognitivno-motoričkog sustava u osnovi rješavanja BOP-testa ne pokazuje povezanosti sa S i ES, iako neznačajna i negativna korelacija s ES ukazuje na logičnu tendenciju (osobe s nestabilnijim BOP-sustavom pokazuju niže vrijednosti ES). Međutim N-BOP pokazuje značajnu, blago nelinearnu, negativnu i nisku povezanost s I, koja objašnjava svega 2% zajedničkih čimbenika, također na očekivani način: osobe koje pokazuju višu N-BOP, u prosjeku pokazuju nešto niži I. Suženi varijabiliteti većine osobina ličnosti i loše osobine raspodjele N-BOP-a svakako ograničavaju dobivanje viših korelacija.

Na kraju, korelacije OP-BOP-a i OO-BOP-a prikazane u Tablici 4. ukazuju na to da u studentskoj populaciji otpornost kognitivno-motoričkog sustava u osnovi rješavanja BOP-testa djelovanju nepovoljnih čimbenika ne pokazuje povezanosti ni s jednom osobinom ličnosti, pa tako ni s ES, S ili I. Pri tome još jednom treba naglasiti kako suženi varijabiliteti većine osobina ličnosti, a eventualno i izrazita negativna asimetrija raspodjele OP-BOP-a i OO-BOP-a, ograničavaju dobivanje viših korelacija.

Rasprava

Prvi i temeljni problem ovog diplomskog rada jest vrednovanje valjanosti tri vida perceptivne brzine kao mjere BOP-a te rezultati njegova obrađivanja predstavljaju izvorni istraživački doprinos s obzirom na prilično inovativne papir-olovka mjere BOP-a koje su rijetko korištene u sličnim istraživanjima. Drugi i treći problem služe vrednovanju modela perceptivne brzine proširenog s ne-prosječnim vidovima funkcioniranja, putem sagledavanja njegova

odnosa s (fluidnom) inteligencijom i osobinama ličnosti, kao temeljnim psihologijskim konceptima.

Mjere dinamike funkcioniranja BOP-sustava koje su korištene u ovom radu dobivene su papir-olovka testom, što omogućuje njihovu primjenu na velike skupine u kratkom vremenu, za razliku od sličnih mjera dinamike BOP koje koriste sofisticirana računala i strojeve, te ne omogućuju skupno testiranje (a što iziskuje puno veće novčano i vremensko ulaganje). Ako se povrh toga dokaže kako su konstrukti mjereni papir-olovka testom statistički i psihometrijski istovjetnih ili sličnih osobina kao kad se mjere računalnim instrumentima, vrijednost testa kao što je KS2-2 postaje očigledna. Budući da se u ovom radu BOP promatra kao ključno svojstvo dinamičkog kognitivno-motoričkog sustava aktiviranog pri rješavanju testa perceptivne brzine, opis tog sustava isključivo putem njegova prosječnog funkcioniranja predstavlja prepojednostavljenje konstrukta BOP iz više razloga. Naime, općenito vrijedi da svaki skup rezultata prikazan centralnom tendencijom ima pripadnu mjeru raspršenja koja te podatke detaljnije opisuje i u tom smislu je svaki opis centralne tendencije koji izostavlja mjeru raspršenja relativno osiromašen (u odnosu na opis koji uključuje mjeru raspršenja). Dodatni argument korištenja ne-prosječnih mjera BOP-a je kriterijska i inkrementalna valjanost intraindividualnog varijabiliteta BOP-a. On se u empirijskim radovima pokazao kao mjera koja može dodatno, uz prosječni pokazatelj BOP-a, objasniti varijancu neke kriterijske varijable, kao što je kvocijent inteligencije (Jensen, 1992). Dakle, premda se djelomično podudara s prosječnom djelotvornošću, on je ipak zasebni vid BOP sustava i valjan razlog razlikovanja nestabilnosti od prosječne djelotvornosti je njena potvrđena kriterijska valjanost. Nadalje, dinamički model BOP-a omogućuje cjelovitiji uvid u taj kognitivno-motorički sustav i pruža podrobniju raščlambu prirode promjene tog sustava u funkciji određenih bitnih čimbenika, poput dobi (Žebec i sur., 2017). Teorijsku i praktičnu vrijednost ovog rada ograničava prigodni studentski uzorak, no s druge strane, podaci su prikupljeni u dva vala mjerenja, kod sličnih, spolno ujednačenih sociodemografskih skupina zbog čega dosljednost nalaza govori u prilog metodološkoj valjanosti istraživanja i psihometrijskoj valjanosti instrumenata.

Rasprava o hipotezama 1. problema

Prva hipoteza

Izravna valjanost PD-BOP visoka je zbog njene brojčane operacionalizacije putem ukupnog broja točno precrtanih ciljnih riječi unutar 60 sekundi, tijekom kojih se opetovano

rješavao uvijek isti zadatak, pa je ukupan rezultat prosječan ishod većeg broja opetovanih kognitivno-motoričkih procesa (posebice ako se podijeli sa 60x4 te se dobije prosječna riješenost zadatka jednoj sekundi).

Premda psihometrijska osjetljivost PD-BOP-a nije optimalna, ona jest dobra, a što se očituje u iznosu koeficijenta varijabilnosti, normalnoj raspodjeli rezultata i odsustvu učinka stropa ili poda.

Iz korelacije PD-BOP s drugim mjerama BOP-a je moguće testirati hipotezu konstruktne, točnije diskriminantne valjanosti. Očekivana niska korelacija s drugim mjerama BOP-a jasno je potvrđena u dva slučaja, kod N-BOP-a (nelinearan odnos) i OO-BOP-a (linearan odnos), a i u slučaju OP-BOP-a više od 50% varijance nije objašnjeno s PD-BOP. Ti nalazi izričito potvrđuju konstruktnu valjanost PD-BOP-a pokazujući kako ta mjera dijeli tek manji dio kognitivnih procesa s preostala tri BOP-pokazatelja. Zamjetna nelinearna korelacija PD-BOP-a i OP-BOP-a dosljedna među dva vala mjerenja (prikazano u Tablici P3. i P4. Priloga) iziskuje daljnja istraživanja tog odnosa. Očekivana nulta povezanost PD-BOP-a s ekstraverzijom i vrlo niska korelacija s ugodnošću također ukazuje na visoku diskriminantnu valjanost korištene mjere.

Konvergentna valjanost PD-BOP-a potvrđena je zbog značajne niske i linearne korelacije što ju ona dijeli s mjerom fluidne inteligencije, a koja je u skladu s teorijskim očekivanjima i prijašnjim istraživanjima tih konstrukata (Sheppard i Vernon, 2008). PD-BOP dijeli nisku linearnu korelaciju s emocionalnom stabilnošću što je također očekivano i govori u prilog konvergentnoj valjanosti korištene mjere. U pogledu dokazivanja konvergentne valjanosti PD-BOP-a, nedostatak povezanosti te mjere sa savjesnošću i s intelektom je nepoželjan nalaz (iako je u prvom valu dobivena niska pozitivna korelacija PD-BOP-a i intelekta – vidi Tablicu P3.). Šira rasprava o tim nalazima provedena je u dijelu koji se u užem smislu tiče tih hipoteza, odnosno drugog i trećeg problema.

Temeljem prethodne interpretacije svih nalaza vezanih uz prvu hipotezu može se zaključiti kako je ona većinom potvrđena.

Druga hipoteza

Izravna valjanost N-BOP je visoka jer je konstrukt operacionaliziran matematičkim izračunom IIV-a u izvedbi svih zadataka. Točnije, operacionaliziran je standardnom devijacijom rezultata svih zadataka riješenih unutar 60 sekundi (koja je mjera prosječnog

odstupanja svakog riješenog zadatka u odnosu na prosjek riješenosti svih zadataka rješavanih unutar 60 sekundi).

U odnosu na PD-BOP, N-BOP je imao lošu osjetljivost: koeficijent varijabilnosti je bio daleko izvan optimalnog raspona, raspodjela rezultata je značajno odstupala od normalne raspodjele i ostvaren je učinak poda. Varijabilitet je bio izrazito proširen jer je standardna devijacija bila gotovo jednaka aritmetičkoj sredini, a mod je bio rezultat nula. Drugim riječima, kod trećine sudionika nije se ni očitovao intraindividualni varijabilitet, a sudionici koji su ga iskazali, donekle su se ravnomjerno raspršili duž svih postignutih vrijednosti. To je vjerojatno posljedica načina na koji su zadaci osmišljeni. Naime, oni su bili izrazito jednostavni i uglavnom nisu ostavljali veliku mogućnost varijacije u odgovorima. Ovdje valja istaknuti raskorak između potrebe postojanja jednostavnih zadataka u mjerama perceptivne brzine s jedne strane, te nedostatne mogućnosti očitovanja varijacije ili intraindividualnog varijabiliteta u odgovorima kod takvih jednostavnih zadataka s druge strane. Iz toga bi se dalo zaključiti kako će taj ne-prosječni pokazatelj imati time poželjniju psihometrijsku osjetljivost što su zadaci kojima se mjeri perceptivna brzina složeniji. Ako je to istinito, jedna preporuka budućim mjerenjima (pomoću testova perceptivne brzine koje koriste jednostavne zadatke) bi bila da se pri primjeni tih testova uključi jedan ili više testova koji imaju složenije zadatke. Na taj bi se način mogla dobiti bolja slika konvergentne valjanosti testa.

Unatoč neosjetljivosti mjere, ona jest pokazala dobru diskriminantnu valjanost u iskazanoj niskoj, negativnoj i nelinearnoj korelaciji s PD-BOP-om i nultoj korelaciji s OP-BOP-om, iz čega slijedi da te mjere zaista procjenjuju različite konstrukte. Zakrivljenost tog odnosa jest sama po sebi vrijedna spoznaja prirode dinamičkog sustava BOP-a i pokazuje opravdanost usporedbe Spearmanovog i Pearsonovog koeficijenta korelacije barem u slučajevima istraživanja dinamičkih osobina nekoga kognitivnog sustava. Premda je za diskriminantnu valjanost niska korelacija N-BOP-a s drugim BOP-mjerama poželjan nalaz, vjerojatno bi se korelacija donekle povećala u slučaju povoljnijih psihometrijskih svojstava N-BOP-mjere, pogotovo u odnosu s OP-BOP-om jer su njihove raspodjele bile suprotno asimetrične. Neovisno o tome bi te korelacije i dalje bile zadovoljavajuće niske jer ti konstrukti nisu u potpunosti neovisni jedan od drugog. Dobivena nelinearna i zamjetna korelacija N-BOP-a i OO-BOP-a, pokazuje da ta dva pokazatelja BOP-a dijele oko 40% kognitivno-motoričkih procesa na očekivani način: osobe s nižom nestabilnošću pokazuju veću otpornost omaškama, na način da se kod njih omaške javljaju tek u kasnijem dijelu rješavanja testa. Taj nalaz je također bio dosljedan među dva vala mjerenja (vidi Tablice P3. i P4. Priloga) i odražava se u jednakosti

smjera (i sličnosti iznosa) povezanosti koju te dvije varijable dijele s mjerom fluidne inteligencije. Isto kao i kod PD-BOP-a, korelacija N-BOP-a s ugodnošću te ekstraverzijom nije dobivena, što dodatno potvrđuje diskriminantnu valjanost mjere nestabilnosti.

Nestabilnost je značajno (premda niže od očekivanog) korelirala s fluidnom inteligencijom što ukazuje na nelošu konvergentnu valjanost. Nadalje, negativna, zakrivljena i niska korelacija N-BOP-a s intelektom predstavlja dodatnu potvrdu konvergentne valjanosti N-BOP-a kao mjere nestabilnosti funkcioniranja BOP-sustava, jer je korelacija s intelektom izostala kod PD-BOP-a (čime se potvrđuje inkrementalna valjanost dinamičkog modela BOP-a u odnosu na modele koje BOP-sustav opisuju isključivo putem nekog prosječnog pokazatelja) Nažalost, izostala je potvrda konvergentne valjanosti N-BOP njenom negativnom korelacijom sa savjesnošću i emocionalnom stabilnošću. S druge strane, prisustvo korelacije emocionalne stabilnosti i PD-BOP u odnosu na odsustvo korelacije emocionalne stabilnost i N-BOP, može se smatrati dodatnom potvrdom diskriminantne valjanosti N-BOP-a i PD-BOP-a, jer pokazuje da te dvije mjere imaju različit odnos s osobinama relevantnim za rješavanje zadataka perceptivne brzine.

Temeljem prethodne interpretacije svih nalaza vezanih uz drugu hipotezu može se zaključiti kako je ona većinom potvrđena, premda u manjoj mjeri nego prva. Taj nedostatak može se vezati uz nepovoljan oblik raspodjele N-BOP varijable te je u budućim istraživanjima potrebno razmotriti može li se on korigirati povećanjem složenosti zadatka perceptivne brzine.

Treća hipoteza

Otpornost BOP-sustava djelovanju nepovoljnih unutarnjih i vanjskih čimbenika (O-BOP) iskazana je pomoću dvije mjere - otpornost pogreškama i otpornost omaškama - te se za izravnu valjanost tih mjera može reći da je visoka. Naime, izdržljivost ili otpornost na djelovanje nepovoljnih čimbenika operacionalizirana matematičkim omjerom prosječnog rednog broja zadatka u kojem se javila prva i druga pogreška ili omaška i rednog broja zadnjeg rješavanog zadatka je logično definirana. Konkretno, omjer je manji kada se pogreška/omaška javi ranije u testu (što se događa kod manje otpornih pojedinaca), a veći ako se pojavi kasnije u testu (što je svojstveno otpornijim pojedincima).

Iznosi koeficijenata varijabilnosti obiju mjera otpornosti bili su unutar optimalnog raspona jer su se rezultati prilično ravnomjerno raspodijelili između vrlo niskih vrijednosti blizu

ništice do vrijednosti ispod jedinice. Međutim, velika većina sudionika je imala vrijednost u iznosu od jedan (ili nešto iznad jedan) što je uzrok izrazitoj negativnoj asimetričnosti raspodjele i pokazuje da je ostvaren učinak stropa. Većina sudionika iskazala je visoku razinu otpornosti na testu perceptivne brzine. Odnosno, ako je netko učinio pogrešku ili omašku učinio ju je bliže kraju testiranja. Moguće je da je lakoća zadataka testa KS2-2 dovela do takvog stanja, analogno pretpostavci o manjoj mogućnosti očitovanja nestabilnosti BOP-a kod jednostavnijih, u odnosu na složenije zadatke.

Pitanje konstruktne valjanosti O-BOP-a zamjetnim dijelom je dotaknuto u raspravi prethodne dvije hipoteze prvog problema. Konkretno, diskriminantna valjanost O-BOP-a je uglavnom dobra, ali je donekle poljuljana zamjetnim korelacijama PD-BOP-a i OP-BOP-a, te N-BOP-a i OO-BOP-a (pri čemu je smjer povezanosti N-BOP-a i OO-BOP-a očekivan, dok smjer povezanosti PD-BOP-a i OP-BOP-a zahtijeva dodatne analize). Međutim, u svim drugim slučajevima su korelacije O-BOP-a ukazivale na visoku diskriminantnu valjanost, i što je zanimljivo, dijelile su nelinearnu korelaciju sa svim mjerama s kojima su značajno korelirale, osim s PD-BOP-om. Pri tome je bitno istaknuti kako je iz dobivene niske međusobne korelacije dvije mjere otpornosti moguće izvući jedan znakovit zaključak: one odražavaju odvojene facete konstrukta otpornosti BOP-sustava djelovanju nepovoljnih čimbenika. Dakle, u ovom radu je potvrđena opravdanost zasebnog mjerenja otpornosti pogreškama i otpornosti omaškama, odnosno, raščlambe općenite otpornosti BOP-sustava djelovanju nepovoljnih utjecaja na barem ove dvije vrste otpornosti. U prilog visokoj diskriminantnoj valjanosti mjera O-BOP-a ide i dobiveni nalaz o nultim korelacijama s ugodnošću i ekstraverzijom.

Podatak o valjanosti O-BOP-a također se može dobiti i iz korelacije mjera O-BOP-a s mjerom fluidne inteligencije. Dobiveni značajni Spearmanovi koeficijenti su u oba slučaja bili niski i značajni, ali suprotnog predznaka što donekle narušava njihovu konvergentnu valjanost i govori u prilog gore navedenim facetama. Konačno, sve korelacije mjera O-BOP-a s relevantnim osobinama ličnosti (S, ES, I) bile su neznačajne, što donekle smanjuje konvergentnu valjanost O-BOP

Temeljem prethodne interpretacije svih nalaza vezanih uz treću hipotezu može se zaključiti kako je ona većinom potvrđena, u sličnoj mjeri kao i druga hipoteza. Izostanak određenog broja očekivanih korelacija – a time i snižena konvergentna valjanost – dijelom se može vezati uz nepovoljan oblik raspodjele OP-BOP i OO-BOP varijable.

Četvrta hipoteza

Posljednja hipoteza prvog problema ispituje statistički značajne zasebne doprinose tri pokazatelja BOP-a u predviđanju fluidne inteligencije, a time i potencijalnu inkrementalnu valjanost. Budući da je u različitim modelima inteligencije (primjerice, u CHC modelu) BOP temeljna sastavnica inteligencije (McGrew, 1997), da je, uz kontrolu obrade i kapacitet reprezentacije, BOP sastavnica najosnovnije razine uma u modelu Demetriou i sur. (2018), kao i da je meta-analiza pola stoljeća istraživanja odnosa inteligencije i BOP-a utvrdila da vrijeme reakcije više korelira s fluidnom, nego li s kristaliziranom inteligencijom - a što vrijedi i za općeniti BOP (Sheppard i Vernon, 2008) - očekuje se da će pojedine sastavnice ili pokazatelji BOP-a, ako zaista jesu zasebni konstrukti, biti značajni prediktori fluidne inteligencije. U svrhu testiranja te hipoteze je provedena linearna regresijska analiza u tri bloka pripadnim trima pokazateljima BOP-a, koja je samo djelomično potvrdila tu hipotezu. Prosječna djelotvornost i OO-BOP su bili značajni prediktori, pri čemu je PD-BOP bio značajniji prediktor od OO-BOP-a. Zajedno su objasnili 13% varijance testa D-2000, s tim da je PD-BOP objašnjavao glavninu te varijance. Taj nalaz je očekivan kada se uzme u obzir da su Sheppard i Vernon (2008) pokazali da međusobne razlike jedne operacionalizacije BOP-a ne može objasniti veliki dio varijance inteligencije. Dobiveni rezultat je snažna potvrda valjanosti PD-BOP-a kao mjere prosječnog funkcioniranja BOP sustava, te potvrda teoretske valjanosti korištenog modela i samog testa KS2-2. Moguće je očekivati da bi se i N-BOP i OP-BOP pojavili kao značajni prediktori g_f kada bi te mjere posjedovale poželjnije psihometrijske osobine, kada ne bi postojao učinak stropa i poda, te kada bi u uzorku bila manje selekcionirana podskupina šire populacije. Osim toga je povezanost OP-BOP i g_f bila nelinearna, a korišten je linearni regresijski model, što bi mogao biti razlog neznačajnoj predikciji OP-BOP-a.

Temeljem gore navedenih interpretacija može se zaključiti kako je četvrta hipoteza polovično potvrđena.

Rasprava o hipotezama 2. Problema

U raspravi prvog problema već su dotaknute hipoteze drugog problema, ali će se na ovom mjestu dodatno raspraviti.

Prva hipoteza

Dobivena niska korelacija PD-BOP-a i g_f (koja je varirala između uzoraka, od 18% zajedničke varijance u prvom do 6% u drugom) potpuno je u skladu s očekivanjima i prijašnjim istraživanjima. Ta korelacija varira između niskih i visokih vrijednosti u različitim radovima,

pri čemu Demetriou i sur. (2010) tvrde da je porast korelacije funkcija složenosti zadataka kojima se mjeri BOP, što su potvrdili Sheppard i Vernon (2008) i pokazali da je opća brzina obrade podataka više povezana s fluidnom, nego li s kristaliziranom inteligencijom i da je ta korelacija u prosjeku niska: iz čega proizlazi sukladnost tih podataka i podataka iz ovog diplomskog rada.

Druga hipoteza

Druga hipoteza je isto potvrđena jer je dobivena niska i negativna korelacija N-BOP-a s g_f. Zanimljivo je istaknuti kako je korelacija g_f i N-BOP bila viša i nelinearna u prvom uzorku, odnosno niža i linearna u objedinjenom uzorku, te uopće nije dobivena u drugom uzorku (vidi Tablicu P3. i P4.). Takva pojava je vjerojatno uvjetovana razlikom u selekcioniranosti drugog uzorka, u odnosu na prvi. Naime, t-test je utvrdio značajnu razliku u aritmetičkim sredinama rezultata na testu D-2000 između uzoraka, na način da je drugi uzorak imao veći prosjek. Razlika se donekle može iščitati i iz veće (ali neznačajne) asimetrije raspodjele mjere g_f kod drugog uzorka u odnosu na prvi (Vidi Tablice P1. i P2. Priloga). Dobivena korelacija ipak je niža od očekivanja s obzirom na slična istraživanja (Jensen, 1992; Deary i sur., 2001) koje su utvrdile nisku povezanost, ali ne toliko nisku kao iz ovog diplomskog rada. Ipak, dobivena korelacija je vrlo povoljan rezultat kada se nedostaci studentskog uzorka (manji varijabilitet u odnosu na širu populaciju – pogotovo u drugom uzorku, u kojem možda baš zbog selekcioniranosti uzorka nije dobivena značajna povezanost varijabli) i same mjere (učinak poda, pozitivna asimetrija i iznos *CV-a* daleko izvan optimalnog raspona) uzmu u obzir. Dakle, kada bi se u sličnom istraživanju zahvatila šira (ne-selekcionirana) populacija, a uz to koristila mjera N-BOP-a s poželjnijim psihometrijskim svojstvima, mogao bi se očekivati i viši iznos korelacije mjere nestabilnosti BOP-sustava i mjere fluidne inteligencije. Ta se povezanost u svakom slučaju očitovala na očekivan način: veća nestabilnost je povezana s manjom inteligencijom.

Treća hipoteza

Razdioba O-BOP-a na otpornost pogreškama i otpornost omaškama nije pronađena u drugim radovima koje su istraživali povezanost pogrešaka na mjerama BOP-a i fluidne inteligencije. Međutim, ako usporedimo korelacije iz istraživanja Dearyja i sur. (2001), koji su mjerili pogreške, možemo utvrditi neke sličnosti. Kao prvo, većina sudionika u njihovom radu nije napravila pogrešku, što je bio slučaj i u ovom diplomskom radu. Kao drugo, te korelacije su također bile niske. Zbog toga možemo ustvrditi da je podatak o povezanosti O-BOP-a i g_f

donekle u skladu s očekivanjima. Ono što je stanovita novost iz ovog rada jest da je između tih varijabli utvrđena nelinearna korelacija. Uzme li se u nepovoljni psihometrijski pokazatelji O-BOP-a i uski segment populacije koji je obuhvaćen (uzorak studenata), kao i nedostatak sličnih radova, rezultat je motivirajući za daljnja istraživanja. Jedna nelogičnost u nalazima jest da su korelacije O-BOP-a s g_f nedosljedne: s OP-BOP-om dijeli negativnu korelaciju, a s OO-BOP-om pozitivnu. Korelacija s OO-BOP-om ipak je logična jer se očekuje da su inteligentniji pojedinci otporniji na omaške, što je potvrđeno. Taj rezultat je još značajniji u pogledu značajne prediktivne uloge i inkrementalne valjanost OO-BOP-a u regresiji fluidne inteligencije.

Rasprava o hipotezama 3. problema

Na kraju ostaje rasprava trećeg problema rada unutar kojeg su ispitane tri hipoteze.

Prva hipoteza

Nedostatak korelacije PD-BOP-a i ES nije u skladu s modelom odnosa BOP-ličnost Chamorro-Premuzica i Fournhama (2004). Bitno je spomenuti da je značajna korelacija ipak dobivena u drugom valu mjerenja, ali nije u prvom (vidljivo iz Tablica P3. i P4. Priloga). Nedostatak korelacije između PD-BOP-a i savjesnosti također nije u skladu s modelom Chamorro-Premuzica i Fournhama (2004). Isto vrijedi za dobivenu povezanost PD-BOP-a i ugodnosti, ali je dobivena povezanost vrlo niska i dijeljena varijanca je oko dva posto, što je prilično neznačajno i u skladu s podacima iz istraživanja Žebeca i sur. (2011). Podaci su prilično dobro uklopljeni u model Demetrioua i sur. (2018) koji predviđa niske ili nulte korelacije BOP-a i samoprocijenjenih osobina ličnosti. Korelacija s intelektom ipak jest očekivana jer je ta osobina u mnogim istraživanjima korelirana s određenim kognitivnim sposobnostima (Demetriou i sur., 2003, Demetriou i sur., 2018) i s općom inteligencijom (Zeidner i Matthews, 2000, Judge i sur., 2007, prema Fournham i sur., 2005). Međutim, ta veza je prije svega odraz povezanosti intelekta s kristaliziranom inteligencijom (Brand, 1994, prema Fournham i sur., 2005). Pri tome je u prvom valu mjerenja ipak dobivena značajna niska i linearna korelacija PD-BOP-a i intelekta, a u drugom je izostala ta povezanost (vidi Tablice P3. i P4.). Mogući razlog toga leži u razlikama među uzorcima o kojima je već bilo riječ. Premda su aritmetičke sredine PD-BOP-a statistički jednake među uzorcima, kod drugog uzorka (u odnosu na prvi uzorak) je vidljiv (u Tablicama P1. i P2. Priloga) pomak prema višim vrijednostima prosjeka,

minimalni i maksimalni iznos je veći, nešto je niži koeficijent varijabilnosti i malo veća negativna asimetrija; no, pitanje je koliko su značajne ove razlike. Svakako su u drugom uzorku bile studentske skupine koje su pri upisu selekcionirane po kriterijima vezanim uz inteligenciju i intelekt. Osim toga, nije nerazumno pretpostaviti izraženije osobine intelekta u skupini studentica i studenata društvenih u odnosu na tehničke discipline.

Druga hipoteza

Najznačajniji nalaz iz ovog dijela jest niska i negativno zakrivljena korelacija N-BOP-a i intelekta. Razlog tome leži u činjenici da intelekt više od ostalih osobina ličnosti dosljedno korelira s općom inteligencijom i prije svega s kristaliziranom inteligencijom (dakle, premda u maloj mjeri, djelomično i s g_f čiji je BOP dio), a u modelu Demetriou i sur. (2018) je intelekt povezan s razvojem složenijih misaonih kapaciteta u pubertetu. Dobiveni podaci u svakom slučaju pokazuju tendenciju postojanja nižeg samoprocijenjenog intelekta kod osoba s većom varijacijom ili nestabilnošću u rješavanju testa perceptivne brzine. Pri tome je dodatan vrijedan nalaz ovog rada otkriće nelinearnog odnosa među varijablama. Istraživači često promatraju Pearsonov koeficijent, ali ga ne uspoređuju sa Spearmanovim koeficijentom, tako da ovaj nalaz može biti svojevrsna motivacija daljnjim istraživanjima i opravdava korištenje dinamičkog modela s ne-prosječnim pokazateljima. Isto tako motivira nalaz da postoji veza između IIV-a BOP-a i nekih osobina ličnosti. Znakovito je što je korelacija nestabilnosti i intelekta bila prisutna u prvom valu mjerenja (i nešto većeg iznosa u odnosu na objedinjen uzorak), ali je u potpunosti izostala u drugom valu mjerenja – vjerojatno zbog razlike među uzorcima koje su već spomenute u raspravi o dobivenoj neznačajnoj korelaciji PD-BOP-a i intelekta. Korelacija je izostala u odnosu N-BOP-a i druge dvije mjere ličnosti relevantne za uspjeh u testu perceptivne brzine. U izostanku sličnih istraživanja s kojima bi se ovi rezultati mogli usporediti je teško zaključiti je li to očekivano ili ne. No, ako se očekuje takav odnos kod prosječnog pokazatelja, a koji jest vezan uz N-BOP, vjerojatno bi taj odnos trebao biti prisutan i kod ovog ne-prosječnog pokazatelja. Bilo bi vrijedno istražiti prirodu odnosa ove mjere s drugim modelima ličnosti, poput HEXACO modela ili nekog modela iz kliničke prakse, poput MMPI. Razlog tome je što mjere perceptivne brzine jesu vezane uz određena klinički relevantna stanja, kao što su problemi u učenju, ali i iz dodatne spoznajne vrijednosti što ju nude višestruke operacionalizacije konstrukata. Primjer toga je rad Demetrioua i sur. (2018) o odnosu kognitivnog razvoja i razvoja ličnosti u kojem su koristili ne samo velepetori model ličnosti, nego i Eysenckov model, te su, kako ističu, tom kombinacijom dobili podatke koje ne bi mogli dobiti korištenjem samo jednog upitnika. Stoga bi preporuka budućim istraživanjima bila da se

dodatno istraži odnos pokazatelja BOP-a s drugim mjerama ličnosti, ali i da se obuhvati širi i manje selekcionirani sloj opće populacije.

Treća hipoteza

Budući da o odnosu O-BOP-a i ličnosti postoji mali broj radova, teško je reći koliko su rezultati u skladu ili raskoraku s očekivanjima. No, ako O-BOP jest povezan s inteligencijom, a što je očekivano i čak utvrđeno u ovom radu, onda bi se mogao očekivati odnos O-BOP-a s intelektom, koji je prilično dosljedno povezan s kristaliziranom (ali i općom) inteligencijom. Međutim, ni u jednom slučaju povezanosti neke osobine ličnosti i O-BOP-a nije dobivena značajna korelacija, što je u skladu s podacima Žebeca i sur. (2011). Autori su pretpostavili da su korelacije pogrešaka u testu koji mjeri BOP i ličnosti podcijenjene zbog malog varijabiliteta mjere pogrešaka, što bi također moglo objasniti nalaze ove hipoteze. Nalazi koji bi donekle mogli motivirati buduća temeljitija i metodološki robusnija istraživanja odnosa ovih varijabli su sljedeći: Spearmanovi koeficijenti korelacije izrazito su se približile graničnoj vrijednosti za odnos ekstraverzije i OP-BOP-a, pri čemu je korelacija negativnog predznaka. Da je korelacija značajna, bila bi donekle u suprotnosti s radom Sočana i Bučika (1998, prema Žebec i sur., 2011) koji su izračunali nisku pozitivnu korelaciju mjere pogrešaka u testu perceptivne brzine i jedne facete ekstraverzije. S druge strane, značajan iznos tog koeficijenta bi se mogao protumačiti u skladu s Eysenckovom teorijom ekstraverzije i neuroticizma (1967, prema Žebec i sur., 2011) prema kojoj se očekuje veća učestalost pogrešaka kod osoba visoke ekstraverzije u usporedbi s introvertima. Još jedno tumačenje je da je u ovom radu konstruktna valjanost OP-BOP-a bila narušena zbog visoke korelacije nje i PD-BOP-a. Međutim, PD-BOP nije korelirao s ekstraverzijom, niti je bio blizu značajnog iznosa. Dodatni nalaz koji bi u nekoj mjeri mogao služiti kao motivacija novih istraživanja na ovu temu jest da se Spearmanov koeficijent korelacije odnosa intelekta i OO-BOP jako približio graničnoj vrijednosti. Budući da je OO-BOP bio značajan prediktor fluidne inteligencije, u slučaju bolje osjetljivosti testa i manje selekcioniranog uzorka bi se mogao očekivati značajan odnos OO-BOP i intelekta.

Zaključak

Cilj ovog diplomskog rada je bio istražiti odnos nekoliko vidova perceptivne brzine, kao mjere BOP-a, s fluidnom inteligencijom i relevantnim dimenzijama velepetorog modela

ličnosti, radi sveobuhvatnijeg sagledavanja teorijskog modela i uloge BOP-a. U tom pogledu je ključni problem bio ispitati valjanost tri vida perceptivne brzine kao mjere BOP-a, prosječne djelotvornosti, nestabilnost i otpornosti djelovanju nepovoljnih čimbenika. Stabilnost nalaza među dva korištena uzorka je opravdalo spajanje dva uzoraka, potvrdilo valjanost korištenih mjera, kao i valjanost metodologije istraživanja.

U objedinjenom uzorku je potvrđeno da su sva tri vida BOP-a valjani pokazatelji različitih dinamičkih sastavnica kognitivno-motoričkog sustava BOP. Psihometrijska osjetljivost bila je najbolja kod PD-BOP-a zbog normalne raspodjele rezultata, koeficijent varijabilnosti je bio nešto ispod optimuma, te nisu postojali dokazi o učinku stropa ili poda. Za razliku od toga su N-BOP, OP-BOP i OO-BOP imale izrazito asimetrične raspodjele (pozitivno asimetrična kod N-BOP-a, negativno asimetrična kod OP- i OO-BOP-a) te prisutne učinke poda (N-BOP) i stropa (OO- i OP-BOP). Te osobine raspodjela ograničavale su postizanje viših korelacija N-BOP, OO- i OP-BOP s drugim varijablama. Potrebno je istaknuti kako je nešto više od pola značajnih korelacija bilo nelinearnog oblika, a većina tih nelinearnih korelacija uključivale su neki BOP-pokazatelj.

Izravna (očigledna) valjanost sva tri pokazatelja dinamike funkcioniranja BOP-sustava je visoka jer je matematičkim izračunom operacionaliziran prosječni uradak u cijelom testu, variranje (nestabilnost) izvedbe od prvog do zadnjeg riješenog zadatka, te otpornost na djelovanje nepovoljnih čimbenika koje se manifestira u ranoj ili kasnoj pojavi pogreške i omaške.

Diskriminantna valjanost BOP-pokazatelja je uglavnom visoka zbog većinom niskih međusobnih korelacija indikatora BOP-sustava, te je donekle narušena zamjetnom zajedničkom varijancom PD-BOP-a i OP-BOP-a, te N-BOP-a i OO-BOP-a. Dvije mjere otpornosti nisko su korelirale, što opravdava valjanost prikaza otpornosti putem otpornosti na pogreške i otpornosti na omaške. Nisku diskriminantnu valjanost BOP-pokazatelja dodatno potvrđuju njihove većinom nepostojeće korelacije sa ekstraverzijom i ugodnošću.

Potvrđena je i umjerena konvergentna valjanost svih pokazatelja BOP-sustava. Naime, u skladu s očekivanjima dobivena je niska pozitivna korelacija g_f i PD-BOP-a (s 10% zajedničke varijance), te niska negativna korelacija g_f i N-BOP-a (s tek 1,5% zajedničke varijance). Mjere otpornosti pokazale su nisku i nelinearnu korelaciju s g_f, premda na nekonzistentan način (OP-BOP je pokazao negativnu, a OO-BOP pozitivnu korelaciju s g_f) što zahtijeva daljnja istraživanja. Konvergentnu valjanost dijelom su potvrdile malobrojne

očekivane (niske) korelacije nekih BOP-pokazatelja s osobinama ličnosti: niska pozitivna korelacija PD-BOP s ES, te niska negativna korelacija N-BOP s I.

Linearna regresijska analiza je pokazala da su PD-BOP i OO-BOP značajni prediktori fluidne inteligencije i da su objasnili očekivanu količinu (oko 12%) varijance, a OO-BOP je iskazao inkrementalnu valjanost povrh PD-BOP-a. Druge se mjere nisu pokazale značajnim prediktorima što može biti rezultat selekcioniranosti uzorka, izrazitih asimetričnosti raspodjela N-BOP i OP-BOP i neprepoznatog nelinearnog odnosa unutar linearne regresije u slučaju OP-BOP-a i g_f.

Gore navedeni rezultati upućuju na sljedeći zaključak prvog problema provedenog istraživanja: dostupne psihometrijske osobine tri pokazatelja dinamike funkcioniranja BOP-sustava ukazuju na njihovu zadovoljavajuću osjetljivost, visoku izravnu valjanost te dobru konstruktnu valjanost. Dodatno pokazuju i polovičnu prediktivnu valjanost u objašnjavanju važnog konstrukta fluidne inteligencije.

Rezultati pod vidom drugog problema istraživanja uglavnom potvrđuju postavljene hipoteze jer je korelacija g_f sa svim BOP-indikatorima značajna: s PD-BOP-om niska i pozitivna, s N-BOP-om niska i negativna, s OO-BOP-om niska i pozitivna. Jedino je niska i negativna korelacija g_f s OP-BOP na prvi pogled neočekivana, no autoru ovog rada nisu dostupni podaci iz literature koji bi odbacili mogućnost da inteligentnije osobe u testovima perceptivne brzine, u prosjeku nešto češće čine pogreške u prvom dijelu testa (ako ih uopće čine). S druge strane, podaci iz literature potvrđuju dobivene korelacije g_f s PD-BOP-om i N-BOP-om.

Nalazi vezani uz treći problem istraživanja govore kako povezanost nije dobivena između većine od tri relevantne dimenzije ličnosti (savjesnost, emocionalna stabilnost, intelekt) i indikatora dinamike funkcioniranja BOP-sustava. Očekivane korelacije dobivene su samo u dva slučaja: očekivana, pozitivna i niska povezanost PD-BOP-a i emocionalne stabilnosti, te očekivana negativna i niska korelacija N-BOP-a i intelekta. Takvi nalazi na prvi pogled mogu se činiti nezadovoljavajućim, no kad se usporede s činjenicom da mjera g_f nije značajno korelirala ni s jednom od relevantnih osobina velepetorog modela ličnosti, oni potvrđuju vrijednost novo-uvedenih BOP-pokazatelja.

Ovo istraživanje je potvrdilo valjanost dinamičkog modela proučavanja kognitivno-motoričkog sustava perceptivne brzine (kao mjere brzine obrade podataka), te je opravdalo

korištenje neprosječnih indikatora BOP-sustava (nestabilnosti i otpornosti djelovanju nepovoljnih čimbenika) pored prosječnog indikatora.

Popis literature

Ackerman, P. L., Beier, M. E. i Boyle, M. D. (2002). Individual Differences in Working Memory Within a Nomological Network of Cognitive and Perceptual Speed Abilities. *Journal of Experimental Psychology: General, 131*(4), 567-589.

Ackerman, P. L. (1999). Psychomotor and Perceptual Speed Abilities and Skilled Performance.

Allen, B. (1994). Perceptual Speed, Learning and Information Retrieval Performance. *Sigir*, 71-80.

Calhoun, S. L. i Mayes, S. D. (2005). Processing Speed in Children With Clinical Disorders. *Psychology in the Schools*, *42*(4), 333-343.

Carroll, J. B. (1993). Human Cognitive Abilities: *A survey of factor-analytic studies*. New York: Cambridge University Press.

Chamorro-Premuzic, T., Stumm, S. V. i Furnham, A. (2015). *The Wiley-Blackwell handbook of individual differences*. Malden, MA: Wiley Blackwell.

Chamorro-Premuzic, T. i Furnham, A. (2004). A Possible Model for Understanding the Personality-Intelligence Interface. *British Journal of Psychology*, *95* (2): 249-264.

Christoff, K., Prabhakaran, V., Dorfman, J., Zhao, Z., Kroger, J. K., Holyoak, K. J., and Gabrieli, J. D. (2001). Rostrolateral Prefrontal Cortex Involvement n Relational Integration During Reasoning. *Neuroimage 14*, 1136–1149.

Ćosić, A. i Matešić, K. (2009). Novi podaci za provjeru valjanosti serije testova domino. *Suvremena psihologija, 12* (2), 425-435.

Danthiir, V., Wilhelm, O., Schulze, R. i Roberts, R. D. (2005). Factor Structure And Validity Of Paper-And-Pencil Measures of Mental Speed: Evidence for a Higher-Order Model? *Intelligence*, *33*(5), 491-514.

Demetriou, A., Spanoudis, G., Žebec, M. S., Andreou, M., Golino, H. i Kazi, S. (2018). Mind-Personality Relations from Childhood to Early Adulthood. *Journal of Intelligence*, *6*(51).

Demetriou, A., Spanoudis, G., Shayer, M., Ven, S. V., Brydges, C. R., Kroesbergen, E., . . . Swanson, H. L. (2014). Relations Between Speed, Working Memory, and Intelligence from Preschool to Adulthood: Structural Equation Modeling of 14 Studies. *Intelligence*, *46*, 107-121.

Demetriou, A., Spanoudis, D. i Shayer, M. (2013). Developmental intelligence: From empirical to hidden constructs. *Intelligence*, *41*, 744–749.

Demetriou, A., Mouyi, A. i Spanoudis, G. (2010). The Development of Mental Processing. *The Handbook of Life-Span Development.*

Demetriou, A., Kyriakides, L. i Avraamidou, C. (2003). The Missing Link in the Relations Between Intelligence And Personality. *Journal of Research in Personality, 37*(6), 547-581.

Demetriou, A., Christou, C., Spanoudis, G. i Platsidou, M. (2002). The Development of Mental Processing: Efficiency, Working Memory, and Thinking. *Monographs of the Society for Research in Child Developent,* 67, (268).

Derakshan, N. i Eysenck, M. W. (2009). Anxiety, Processing Efficiency, and Cognitive Performance. *European Psychologist, 14*(2), 168-176.

Diehl, M., Hooker, K. i Sliwinski, M. J. (2015). Intraindividual Variability and Covariation Across Domains in Adulthood and Aging iz: *Handbook of intraindividual variability across the life span*. New York, NY: Routledge, 258 – 261.

Drenovac, M. (2009). Kronometrija dinamike mentalnog procesiranja. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku; Filozofski fakaultet, Osijek.

Eizaguirre, M. B., Vanotti, S., Merino, Á, Yastremiz, C., Silva, B., Alonso, R. i Garcea, O. (2018). The Role of Information Processing Speed in Clinical and Social Support Variables of Patients with Multiple Sclerosis. *Journal of Clinical Neurology, 14*(4), 472.

Ferrer, E. (2009). Fluid Reasoning and the Developing Brain. *Frontiers in Neuroscience*, *3*(1).

Furnham, A., Moutafi, J. i Chamorro-Premuzic, T. (2005). Personality and Intelligence: Gender, the Big Five, Self-Estimated and Psychometric Intelligence. *International Journal of Selection and Assessment*, *13*(1), 11-24.

Goldberg, L. R. (1990). An Alternative "Description of Personality": The Big-Five Factor Structure. *Journal of Personality and Social Psychology*, *59*(6),1216-1229.

Gottfredson, L. S. (1997). Why g Matters: The complexity of everyday life. *Intelligence*, *24*(1), 79-132.

Jensen, A. R. (2007). Clocking the Mind: Mental Chronometry and Individual Differences. Amsterdam: Elsevier.

Jensen, A. R. (1992). The Importance of Intraindividual Variation In Reaction Time. *Personality and Individual Differences*, *13*(8), 869–881.

Kranzler, J. H. (1992). A Test of Larson and Aldertons (1990) Worst Performance Rule of Reaction Time Variability. *Personality and Individual Differences*, *13*(3), 255–261.

Kroger, J. K., Sabb, F. W., Fales, C. L., Bookheimer, S. Y., Cohen, M. S., and Holyoak, K. J. (2002). Recruitment of Anterior Dorsolateral Prefrontal Cortex In Human Reasoning: A Parametric Study of Relational Complexity. *Cereb. Cortex 12*, 477–485.

Kuang, S. (2017). "Is Reaction Time an Index of White Matter Connectivity During Training?". *Cognitive Neuroscience, 8* (2): 126–128.

Larson, G. E. i Alderton, D. L. (1990). Reaction Time Variability and Intelligence: a "Worst Performance" Analysis Of Individual Differences. *Intelligence*, *14*(3), 309–325

Luciano, M., Posthuma, D., Wright, M.J., de Geus, E.J.C., Smith, G.A., Geffen, G.M., Boomsma, D.I. i Martin, N.G. (2005). Perceptual Speed Does Not Cause Intelligence, and Intelligence Does Not Cause Perceptual Speed. *Biol. Psychol. 70* (1), 1 –8.

Madden, D. J. (2001). Speed and Timing of Behavioural Processes. In J. E. Birren i K. W. Schaie (urednici.), *Handbook of the psychology of aging* (5. izd.). San Diego, CA: Academic Press.

Matešić, K., Matešić, K. ml. i Ružić, V. (2009). Hrvatska standardizacija testa D-2000. U K. Matešić (Ur.): *Priručnik za primjenu Testa D-2000.* (str. 31-45). Jastrebarsko: Naklada Slap.

McCrae, R. R. i Costa, P. T. (1999). A Five-Factor Theory of Personality. Pervin, L. A. i John, O. P. (urednici)., *Handbook of personality: Theory and research*. New York, NY, US: Guilford Press.

Mead, A. D. i Drasgow, F. (1993). Equivalence of Computerized and Paper-And-Pencil Cognitive Ability Tests: A Meta-Analysis. *Psychological Bulletin, 114*(3), 449-458.

Mlačić, B. i Goldberg, L.R. (2007). An analysis of a Cross-Cultural Personality Inventory: The IPIP Big-Five Factor Markers in Croatia. *Journal of Personality Assessment, 88*(2), 168-177.

Mlačić, B., Milas, G. i Kratohvil, A. (2007). Adolescent Personality and Self-Esteem – an Analysis of Self-Reports and Parental-Ratings. *Društvena istraživanja, 1-2* (87-88), 213-236.

Momirović, K. i Kovačević, V. (1970). Evaluacija dijagnostičkih metoda. Zagreb: Republički zavod za zapošljavanje.

Penke, L., Maniega, S. M., Bastin, M. E., Hernández, M. C., Murray, C., Royle, N. A., . . . Deary, I. J. (2012). Brain White Matter Tract Integrity as a Neural Foundation for General Intelligence. *Molecular Psychiatry*, *17*(10), 1026-1030.

Rammsayer, T.H. i Troche, S.J. (2010). Effects of Age and the Relationship Between Response Time Measures and Psychometric Intelligence in Younger Adults. *Personality and Individual Differences 48* (2010) 49–53.

Reed, T. E. (1998). Causes of Intraindividual Variability In Reaction Times: A Neurophysiologically Oriented Review and a New Suggestion. *Personality and Individual Differences, 25*(5), 991-998.

Reeve, C. L., Meyer, R. D. i Bonaccio, S. (2006). Intelligence-Personality Associations Reconsidered: The Importance of Distinguishing between General and Narrow Dimensions of Intelligence. *Intelligence, 34*(4): 387-402.

Schweizer, K. (1993). The Contribution of Access to External Information, Stimulus Complexity, and Variability to Cognitive Abilities. *Personality and Individual Differences*, *14*(1), 87-95.

Sheppard, L. D. i Vernon, P.A. (2008). Intelligence and Speed of Information-Processing: a Review of 50 Years Of Research. *Personality and Individual Differences 44*, 535–551.

Soto, C. J. (2018). Big Five Personality Traits. In M. H. Bornstein, M. E. Arterberry, K. L. Fingerman i Lansford, J. E. (urednici.), The SAGE encyclopedia of lifespan human development (str. 240-241). Thousand Oaks, CA: Sage.

Sweet, L. H. (2011) Information Processing Speed. Kreutzer, J. S., DeLuca J. i Caplan B. (urednici) Encyclopedia of Clinical Neuropsychology. Springer, New York, NY.

Žebec, M. S., Crnko, I., Palavra, V. i Sumpor, D. (2017). Pokazatelji dinamike funkcioniranja selektivne pažnje hrvatskih strojovođa i njihove dobne razlike. *Sigurnost, 59* (4), 331-354.

Žebec, M. S., Palavra, V. i Sumpor, D. (2016). Perceptual speed of Croatian railroad engineers from 25 to 59 years of age: Empirical findings and implications. In *6th International Ergonomics Conference „Ergonomics 2016-Focus on synergy"*.

Žebec, M. S., Budimir, S., Merkaš, M., Szirovitzca, L. i Živičnjak, M. (2014). Sex-Specific Age-Related Changes of Information Processing Rate Indicators During Childhood and Adolescence *Collegium Antropologicum, 38*(2), 397-408.

Žebec, M. S., Kopačević, D. i Mlačić, B. (2011). Relationship Between The Big-Five Personality Dimensions And Speed Of Information Processing Among Adolescents. *Društvena Istraživanja, 20*(2 (112)), 435-455.

Žebec, M. S. (2004). A contribution to the analysis of human speed of information processing: Developmental and differential arguments. *Društvena istraživanja, 13*,1-2, 267-292.

Prilog

Deskriptivna statistika varijabli dva uzorka

Na uzorcima je analizirana deskriptivna statistika kako bi se provjerile neke pretpostavke računanja linearne korelacije među varijablama na prvom i na drugom ispitanom uzorku. Osim toga, pregled deskriptivne statistike dvaju različitih uzoraka daje uvid u stupanj sličnosti odnosno različitosti dvaju uzoraka u pogledu promatranih obilježja, što će se odraziti na mogućnost spajanja uzoraka te na snagu dobivenih korelacijskih nalaza (posebice ako se razmatraju na zasebnim uzorcima). Budući da su isti instrumenti (primijenjeni u standardiziranim uvjetima) korišteni na dva osobama različita, ali socio-demografski slična

uzorka, svaka sličnost statistika među uzorcima ide u prilog zaključku da se radi o psihometrijski valjanim instrumentima i metodološki ispravnom istraživanju. Ispod su navedene Tablice P1. i P2. provedenih deskriptivnih analiza. U prvom uzorku su studenti Fakulteta prometnih znanosti (FPZ-a) - smjer cestovni promet, a u drugom su studenti Hrvatskih studija (HS-a), konkretno, psihologije, komunikologije i filozofije – te manji uzorak studenata FPZ-a - smjer aeronautika.

Tablica P1. *Deskriptivna statistika studenata FPZ-a (cestovni promet)*

		gf	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
N	Valjani	97	96	96	97	97	89	89	89	89	89
	Nedostaju	0	1	1	0	0	8	8	8	8	8
M		16,2	99,6	0,3	1	0,9	3,5	3,8	3,7	3,4	3,5
Sd		4,73	16,65	0,23	0,21	0,23	0,61	0,65	0,6	0,71	0,48
Mdn (C)		16	99,5	0,2	1	1	3,6	3,9	3,7	3,5	3,6
iq		6,5	30,5	0,43	0	0	1	0,8	0,9	1	0,7
min		4	66	0	0,1	0,1	1,8	0,2	1,8	1,7	2,2
max		30	137	0,9	1,1	1,1	4,8	5	5	4,9	4,7
CV		29,2	16,7	88,3	21,5	24,8	17,3	17,3	16,4	20,9	13,4
z		-0,87	0,33	1,55	-11,42	-9,72	-0,76	-6,85	-1,57	-1,17	-0,17
SW	Statistik	0,979	0,976	0,898	0,458	0,581	0,987	0,883	0,982	0,984	0,992
	df	88	88	96	88	88	88	88	88	88	88
	Sig.	0,168	0,1	0,001	0,001	0,001	0,559	0,001	0,245	0,354	0,896

Napomena: g_f je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt, z je mjera asimetrije raspodjele i SW označava Shapiro-Wilk statistike

Tablica P2. *Deskriptivna statistika studenata HS-a (psihologije, komunikologije i filozofije) i FPZ-a (aeronautika)*

		gf	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
N	Valjani	105	97	97	102	102	110	110	110	110	110
	Nedostaju	7	15	15	10	10	2	2	2	2	2
M		18,6	98,7	0,3	0,9	0,9	3,3	3,9	3,6	3,1	3,7
Sd		5,35	13,6	0,25	0,23	0,24	0,72	0,56	0,67	0,77	0,46
Mdn (C)		19	98	0,2	1	1	3,4	4	3,6	3,1	3,8
iq		6,5	16	0,41	0	0,1	1	0,7	1	1,2	0,7
min		4	51	0	0,1	0,1	1,6	2,1	1,7	1,2	2,7
max		31	138	1,3	1,1	1,1	5	5	4,8	4,7	4,8
CV		28,8	13,8	99,4	24,6	27,1	21,6	14,4	18,6	25,1	12,3

	z	-1,69	-0,73	4,67	-9,92	-7,97	-0,48	-3,78	-1,98	-0,53	-0,53
	Statistik	0,978	0,973	0,862	0,514	0,618	0,989	0,965	0,977	0,985	0,984
SW	*df*	93	93	97	93	93	93	93	93	93	93
	Sig.	0,122	0,048	0,001	0,001	0,001	0,67	0,013	0,108	0,365	0,302

Napomena: g_f je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt, z je mjera asimetrije raspodjele i SW označava Shapiro-Wilk statistike

Uzorci imaju sličan broj sudionika ($N \approx 100$). Vrijednosti svih varijabli mjerene su na intervalnoj ili omjernoj skali zadovoljavajući time prvi uvjet računanja Pearsonovog koeficijenta korelacije.

Sljedeći podatak koji ukazuje na prikladnost varijabli za izračun korelacije primjetan je iz vrijednosti koeficijenta varijabilnosti (*CV*). Iz *CV*-a se može saznati je li varijabilitet sužen ili proširen, može se usporediti varijabilitet varijabli i uvidjeti u kojim je raspodjelama aritmetička sredina prikladni statistik u opisu raspodjele. Primjetno je kako vrijednosti *CV-a* ima prilično slične vrijednosti među uzorcima, a optimalne vrijednosti (*između 20 i 30%*) u oba uzorka poprima za g_f, OP-BOP, OO-BOP i ES. Taj koeficijent poprima optimalnu vrijednost i za varijablu ekstraverzije u drugom, ali ne i prvom uzorku. Ostale varijable imaju sužen varijabilitet očitovan u vrijednostima koeficijenta varijabilnosti koji je manje od 20%, a najniže vrijednosti u oba uzorka poprima intelekt. PD-BOP ima suženiji varijabilitet u drugom, nego li u prvom uzorku. Mjera savjesnosti se približava optimalnoj vrijednosti u oba uzorka, s tim da je varijabilitet malo više sužen u prvom uzorku, u odnosu na drugi uzorak. U varijabli ugodnosti je *CV* nešto veći u prvom uzorku, nego li u drugom uzorku. Izrazito prošireni varijabilitet dobiven je za varijablu N-BOP zbog toga što je standardna devijacija te mjere gotovo jednaka aritmetičkoj sredini, što će ishoditi podcijenjenim korelacijama. Analiza *CV*-a dvaju uzoraka pokazuje da je kod najvećeg broja promatranih varijabli dva uzorka utvrđeno postojanje istovjetnih svojstva varijabli s obzirom na stupanj optimalnosti varijabiliteta. To znači da iste varijable dosljedno pokazuju bilo optimalan, bilo smanjen varijabilitet – ne postoji slučaj u kojem je ista varijabla u jednom uzorku pokazala smanjeni varijabilitet, a u drugom uzorku povećani varijabilitet. Dakle, time se potvrđuje sličnost uzoraka, kao i dosljednost te valjanost metode mjerenja.

Iz Tablica P1. i P.2 moguće je donekle vidjeti jesu li vrijednosti varijable normalno raspodijeljene te jesu li u dva različita uzorka na sličan način raspodijeljene. Dijeleći statistik *skewness*s pripadnom standardnom pogreškom ($z = \frac{skewness}{s.e.skewness}$) i uzimajući vrijednost |1,96|

kao granicu unutar koje možemo zaključiti kako se radi o simetričnim raspodjelama, iz tablice je moguće zaključiti kako se vrijednosti svih varijabli simetrično raspodjeljuju, s iznimkom sljedećih varijabli: intraindividualnog varijabiliteta (u drugom uzorku), otpornosti pogreškama, otpornosti omaškama i mjere ugodnosti. Ove nalaze valja protumačiti u kontekstu toga da su pogreške i omaške na zadacima testa KS2-2 bile su vrlo rijetke, odnosno pojedinci većinom nisu pravili pogreške ili omaške. Drugim riječima, većina ispitanika imala je visoku otpornost i na pogreške i na omaške. Dodatno, odstupanje vrijednosti mjere ugodnosti od simetrične raspodjele i nije začuđujuća uvidimo li kako se ta mjera odnosi na ponašajne sklonosti u kontekstu ugodnih i pozitivnih međuljudskih odnosa i ponašanja gdje je izražena društvena poželjnost odgovaranja, ali i stvarnog ponašanja s tendencijom prema većoj ugodnosti odnosno pozitivnijim vrijednostima. Zbirna analiza pokazatelja stupnja simetričnosti pokazuje da gotovo sve varijable pokazuju isti stupanj simetričnosti u dva uzorka, ukazujući time i na (socio-demografsku) sličnost uzoraka, i na valjanu primjenu metode mjerenja.

Vrijednosti Shapiro-Wilk testova normalnosti daju značajna odstupanja ($p < 0,05$) za neke, ali ne sve varijable kod kojih je uočena značajna asimetrija: N-BOP, OP-BOP, OO-BOP i U. Shapiro-Wilk statistik ukazuje na to da raspodjela varijable ukupnih točno precrtanih riječi na testu KS2-2 (PD-BOP) odstupa od normalne raspodjele u drugom uzorku. Vrijedan podatak ovih testova je da oni pokazuju kako postoje gotovo istovjetna odstupanja od normaliteta u dva uzorka. Taj podatak ukazuje na prikladnost zbrajanja dva uzorka u cjelinu, a isto tako (uzevši u obzir socio-demografsku sličnost uzoraka) dokazuje dosljednost i valjanost korištene metodologije.

Proveden je t-test na nezavisnim uzorcima u svrhu provjere potencijalnih razlika aritmetičkih sredina varijabli među uzorcima, te provjere homogenosti varijanci varijabli među uzorcima. Iako homogenost varijanci nije nužan uvjet računanja korelacije, ipak je poželjan. U Tablici P3. Su prikazani ti rezultati.

Tablica P3. *Leveneov test homogenosti vaijanci i t-test jednakosti aritmetičkih sredina među uzorcima*

	Leveneov test		t-test jednakosti aritmetičkih sredina		
	F	*p*	*t*	*df*	*p*
g_f	1,85	0,175	-3,37	200	0,001**
PD-BOP	9,8	0,002**	0,44	191	0,663
N-BOP	0	0,948	0,24	191	0,811
OP-BOP	1,37	0,243	0,67	197	0,501
OO-BOP	1,19	0,277	0,59	197	0,558
E	2,93	0,089	1,89	197	0,06
U	0,33	0,569	-1,75	197	0,082
S	1,26	0,263	1,22	197	0,223
ES	0,73	0,393	3,15	197	0,002**
I	0	0,954	-3,05	197	0,003**

*Napomena: ** $p < 0.01$, * $p < 0.05$, g_f je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt*

Iz Tablice P3. vidljivo je da je homogenost varijanci značajno narušena samo u varijabli PD-BOP. Osim toga, nalazi ukazuju na značajna odstupanja aritmetičkih sredina g_f, ES i I. Temeljem provedenih testova razvidno je kako se dva uzorka studenata u 90% promatranih varijabli ne razlikuju s obzirom na njihov varijabilitet, dok se u pogledu centralne tendencije razlikuju samo u 30% varijabli.

Korelacijske matrice varijabli dva uzorka

Prije navođenja korelacijskih tablica kojima se ispituju glavne hipoteze potrebno je provjeriti je li kod ispitanika oba uzorka bila prisutna strategija rješavanja „brzina na uštrb točnosti“, odnosno *speed-accuracy trade-off*. To se provjerava izračunom korelacije između ukupnog broja riješenih zadataka (PD-BOP) i ukupnog broja netočnosti: ako je ta korelacija statistički značajna i pozitivna, onda ta strategija postoji.

Rezultati računanja Pearson (r) i Spearman (r_s) koeficijenata korelacije pokazuju kako ni u prvom (r= -0,033, p > 0,5; r_s = -0,078, p > 0,5), ni u drugom uzorku (r = 0,131, p > 0,2; r_s=0,109, p > 0,2) ta strategija nije bila prisutna, premda je u drugom uzorku postojala blaga tendencija k njoj).

Izračun korelacije je proveden kako bi se testirale hipoteze koje ispituju valjanost tri pokazatelja dinamike funkcioniranja perceptivno-motoričkog sustava BOP: prosječne efikasnosti, nestabilnosti i otpornosti na djelovanje nepovoljnih čimbenika. Osim toga, ispituje se odnos tih pokazatelja s uratkom na testu fluidne inteligencije D-2000, ali i s dobivenim rezultatima mjera emocionalne stabilnosti, savjesnosti i intelekta. Osim Pearsonove linearne korelacije, provedena je i Spearmanova rang korelacija. Usporedbom veličine koeficijenata dvaju statistika korelacije moguće je spoznati postoji li linearan ili zakrivljen odnos određenih varijabli. Prva tablica prikazuje uzorak studenata FPZ-a, smjer cestovnog prometa (označeno jedinicom), a druga tablica uzorak studenata HS-a, smjerovi psihologija, komunikologija i filozofija te studenata FPZ-a – smjer aeronautike (označeno dvojkom). Isto tako, redoslijed tablica je takav da se prvo prikazuju rezultati Pearson korelacije, zatim Spearmanove korelacije.

Tablica P4. *Pearsonove i Spearmanove korelacije studenata FPZ-a*

		g_f	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
g_f	Pearson	1	0,427**	-0,163	-0,021	0,149	-0,12	0,075	-0,057	0,083	0,185
	Spearman		0,406**	-0,169*	-0,310**	0,208*	-0,087	-0,026	-0,013	0,08	0,191
	N	97	96	96	97	97	89	89	89	89	89
PD-BOP	Pearson		1	-0,185	0,016	-0,278**	0,112	0,276**	0,122	0,144	0,220*
	Spearman			-0,242*	-0,710**	-0,17	0,104	0,251*	0,15	0,157	0,179
	N		96	96	96	96	88	88	88	88	88
N-BOP	Pearson			1	-0,330**	-0,213*	-0,16	-0,084	0,005	-0,143	-0,30**
	Spearman				-0,024	-0,638**	-0,136	-0,144	0,015	-0,17	-0,326**
	N			96	96	96	88	88	88	88	88
OP-BOP	Pearson				1	0,135	0,04	-0,085	-0,067	0,093	-0,084
	Spearman					0,231*	-0,069	-0,186	-0,135	-0,057	-0,19
	N				97	97	89	89	89	89	89
OO-BOP	Pearson					1	0,047	0,041	0,043	0,106	0,055
	Spearman						0,137	0,095	-0,042	0,074	0,236*
	N					97	89	89	89	89	89
E	Pearson						1	0,274**	0,104	,318**	0,389**
	Spearman							0,286**	0,116	,306**	0,412**
	N						89	89	89	89	89
U	Pearson							1	0,215*	0,151	0,175
	Spearman								0,241*	0,136	0,231*
	N							89	89	89	89
S	Pearson								1	0,129	0,281**
	Spearman									0,121	0,294**
	N								89	89	89
ES	Pearson										0,219*
	Spearman										0,243*
	N										89

*Napomena: ** p < 0.01, * p < 0.05 , gf je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt*

Od 45 korelacija u matrici njih 21 bio je značajan – bilo da su izračunate Pearsonovim ili Spearmanovim koeficijentom. No, važno je istaknuti kako je od tog 21 značajnoga kod čak 14 njih Spearmanov koeficijent bio veći od Pearsonovog. To znači da kod svih onih parova varijabli kod kojih je korelacija značajna, čak 66% (ili 2/3) njih nelinearne. Dodatno se može

uvidjeti da od tih 14 značajnih nelinearnih korelacija, njih 8 (ili 57%) uključuju tri ne-prosječne mjere BOP-a: N-BOP, OP-BOP i OO-BOP.

Korelacije indikatora dinamike funkcioniranja BOP-sustava prvog uzorka

Promatrajući međusobne korelacije pokazatelja dinamike funkcioniranja BOP-sustava uviđa se kako postoji niska zakrivljena povezanost PD-BOP-a i N-BOP-a. Povezanost PD-BOP-a i OP-BOP-a je visoka, negativna i zakrivljena. Povezanost PD-BOP i OO-BOP-a je prilično niska, negativna i linearna. Odnos PD-BOP s ostalim pokazateljima dinamike funkcioniranja BOP daje djelomično očekivane, ali i djelomično neočekivane rezultate. Naime, osobe koje su postigle veći PD-BOP (mjera prosječne djelotvornosti kognitivnog sustava) imaju manju N-BOP (mjera nestabilnosti kognitivnog sustava), što je potpuno u skladu s očekivanjima. Međutim, očekivalo bi se da osobe s većim PD-BOP imaju i veću otpornost na pogreške i omaške, a dobiven je suprotan nalaz – što je netko imao veći PD-BOP, to je imao prosječno manju otpornost pogreškama i nešto manju otpornost omaškama. Taj neočekivan rezultat vjerojatno odražava najčešći redni broj zadatka u kojem se javila prva/druga pogreška/omaška. Naime, dvije mjere otpornosti imale su (u oba uzorka) iznimnu negativnu asimetriju, pri čemu je minimalna vrijednost iznosila 0,1 i maksimalna 1,1, a medijan mjera jednak 1,0 (što znači da se pogreška/omaška, ako se javljala, javljala u zadnjem zadatku) i pokazuje učinak stropa. Dakle, pogreške i omaške se najčešće javljaju vrlo blizu zadnje rješenog zadatka i tu nije toliko neobično ako brža osoba napravi pogrešku/omašku koji dio zadatka ranije od sporije osobe.

Povezanost N-BOP-a i OP-BOP-a je niska, negativna i linearna, dok su N-BOP i OO-BOP su prilično visoko, negativno i nelinearno povezane. Teorijski gledano, dobivene povezanosti bi trebale biti negativne (jer veća nestabilnost implicira manju otpornost na pogreške i omaške), tako da su dobiveni nalazi u skladu s očekivanjima.

Zadnji pokazatelji dinamike funkcioniranja BOP-ssustava su dvije mjere otpornosti na djelovanje nepovoljnih čimbenika – OP-BOP i OO-BOP. Dijele nisku i pozitivnu korelaciju, što ukazuje na to da u osnovi te dvije vrste netočnosti stoji samo mali dio zajedničkih kognitivnih procesa, što je u skladu s teorijskim očekivanjima i što opravdava odvojeno mjerenje otpornosti pogreškama i otpornosti omaškama.

Korelacije pokazatelja BOP-sustava i mjere fluidne inteligencije

Iščitavajući odnos g_f i PD-BOP-a iz tablica korelacija primjetna je relativno visoka pozitivna Pearsonova korelacija jer su uobičajene mjere povezanosti fluidne inteligencije i BOP-a oko 0,3.

Fluidna inteligencija dijeli nelinearnu, negativnu i nisku povezanost s N-BOP-om.

Promatrajući korelaciju g_f i dvije mjere otpornosti na djelovanje nepovoljnih čimbenika uviđa se kako je riječ o zakrivljenom odnosu varijabli. Naime, g_f i OP-BOP pokazuju zakrivljenu i nisku negativnu korelaciju. Ovaj rezultat je neočekivan zato što se očekuje da su inteligentniji pojedinci otporniji na pogreške, no takav ishod opet se može objasniti činjenicom da se pogreške najčešće javljaju vrlo blizu zadnje rješavanog zadatka i tu nije toliko neobično ako inteligentnija osoba u prosjeku napravi pogrešku koji dio zadatka ranije od sporije ili manje inteligentne osobe. Korelacija g_f i OO-BOP-a je nelinearna i niža, ali je smjer kretanja korelacije logičan – što je pojedinac veće inteligencije, nešto je i otporniji na omaške.

Korelacije pokazatelja BOP-sustava i tri osobine ličnosti

Između PD-BOP i ES nije dobivena značajna korelacija. Budući da se teorijski očekuje da djelotvorniji pojedinci jesu emocionalno stabilniji, ovaj nalaz odstupa od očekivanja, pri čemu povezanost, premda neznačajana, ide u logičnom smjeru. Isto vrijedi i za u korelaciju PD-BOP i savjesnosti, što također odstupa od očekivanja.

Za razliku od toga je dobivena linearna i niska povezanost PD-BOP-a i intelekta, što je u skladu s očekivanjima da oni koji su djelotvorniji imaju višu samoprocjenu intelekta.

Nije dobivena povezanost N-BOP-a i emocionalne stabilnosti. Budući da je očekivana povezanost veće nestabilnosti BOP-sustava i veće emocionalne stabilnosti, ovaj nalaz također odstupa od očekivanja. Međutim, smjer kretanja (neznačajne) korelacije jest očekivan i logičan. Kod odnosa N-BOP-a i savjesnosti također nije dobivena korelacija i to je donekle neočekivano jer bi veća nestabilnost u rješavanju zadataka trebala biti povezana s manjom savjesnošću. S druge strane, N-BOP i intelekt dijele negativnu i nisku korelaciju, što predstavlja nalaz koji je u skladu s očekivanjima o povezanosti manjeg samoprocijenjenog intelekta i veće nestabilnosti u rješavanju zadataka.

Mjere otpornosti pogreškama (OP-BOP) i tri osobine ličnosti ni u jednom slučaju ne dijele korelaciju. Teorijski se očekuje da je OP-BOP pozitivno korelirana s ovim čimbenicima

ličnosti. Međutim, malo je radova pronađeno na ovu temu tako da su potrebna dodatna istraživanja koja bi dodatno rasvijetlila te odnose.

S druge strane je dobivena nelinearna i niska korelacija OO-BOP-a i intelekta koji je logičan zato što se očekuje da pojedinci koji su otporniji na omaške imaju više izražen intelekt.

Emocionalna stabilnost i savjesnost ne koreliraju s OO-BOP-om, iako su očekivane pozitivne korelacije ovih varijabli, no, ponovno je potreban je oprez u tumačenju ovih nalaza jer je mali broj radova pronađen na ovu temu.

Slijedi prikaz matrice korelacije analogne Tablici P4., ali za drugi uzorak, u svrhu ispitivanja istih hipoteza i u svrhu uvida u stupanj sličnosti uzoraka u međusobnim korelacijama varijabli istraživanja.

Tablica P5. *Pearsonove i Spearmanove korelacije studenata aeronautike, psihologije, komunikologije i filozofije*

		g_f	PD-BOP	N-BOP	OP-BOP	OO-BOP	E	U	S	ES	I
g_f	Pearson	1	0,252*	-0,093	-0,058	0,04	0,069	-0,019	-0,061	0,098	0,011
	Spearman		0,173	-0,046	-0,108	0,089	0,014	-0,084	-0,076	0,071	-0,003
	N	105	95	95	100	100	103	103	103	103	103
PD-BOP	Pearson		1	-0,05	-0,237*	-0,327**	0,047	-0,018	0,035	0,249*	0,012
	Spearman			-0,07	-0,674**	-0,322**	0,014	-0,021	0,012	0,189	0,008
	N		97	96	97	97	95	95	95	95	95
N-BOP	Pearson			1	0,145	-0,347**	0,031	-0,034	0,124	-0,048	-0,028
	Spearman				0,04	-0,675**	0,009	-0,045	0,102	-0,057	-0,074
	N			97	97	97	95	95	95	95	95
OP-BOP	Pearson				1	-0,039	-0,156	0,042	0,064	-0,037	0,183
	Spearman					0,215*	-0,181	-0,014	0,142	-0,066	0,039
	N				102	102	100	100	100	100	100
OO-BOP	Pearson					1	-0,034	-0,186	-0,167	-0,175	0,032
	Spearman						-0,064	-0,046	-0,165	-0,107	0,056
	N					102	100	100	100	100	100
E	Pearson						1	0,083	-0,116	0,315**	0,151
	Spearman							0,001	-0,113	0,296**	0,163
	N						110	110	110	110	110
U	Pearson							1	0,076	-0,039	-0,001
	Spearman								0,036	-0,108	0,138
	N							110	110	110	110
S	Pearson								1	0,177	-0,034
	Spearman									0,163	-0,030
	N								110	110	110
ES	Pearson									1	0,07
	Spearman										0,053
	N									110	110

*Napomena: ** p < 0.01, * p < 0.05 , gf je fluidna inteligencija, PD-BOP je prosječna djelotvornost BOP-a, N-BOP je nestabilnost BOP-a, OP-BOP i OO-BOP mjere otpornosti (pogreškama i omaškama) BOP-a, E je ekstraverzija, U je ugodnost, S je savjesnost, ES je emocionalna stabilnost, I je intelekt*

Kao i u prvoj matrici korelacije ova sadrži 45 korelacija. Prva uočljiva razlika u odnosu na prvu matricu jest u broju značajnih koeficijenata korelacije (bilo da je riječ o Pearsonovom ili Spearmanovom koeficijentu) – u ovom slučaju ih je tek sedam. Druga razlika je u broju slučaja kada je Spearmanov koeficijent veći od Pearsonovog, odnosno u kojima se javlja nelinearan odnos. Od sedam korelacija, četiri ima veći Pearsonov koeficijent, a tri imaju veći Spearmanov koeficijent. Nadalje, razvidno je da sve tri nelinearne korelacije uključuju tri ne-

prosječne mjere BOP-a: N-BOP, OP-BOP i OO-BOP. Primjetna je veća sličnost među matricama u „kognitivnim“ varijablama (inteligenciji i pokazateljima BOP-sustava), odnosno manja sličnost korelacija vezanih uz osobine ličnosti. Sličnosti korelacija među kognitivnim varijablama očituje se, npr., u tome što su one korelacije koje su nelinearne u prvom uzorku, nelinearne i u drugom uzorku (s iznimkom korelacije g_f i tri ne-prosječna pokazatelja koja su statistički jednaka nuli). Što se korelacije mjera velepetorih osobina ličnosti tiče, razlika među matricama je vidljiva, primjerice, u tome što je intelekt u prvom uzorku korelirao sa svim čimbenicima ličnosti i uz to još s PD-BOP-om, N-BOP-om i OO-BOP-om; dok u drugom uzorku intelekt ni s jednim pokazateljem BOP-sustava ne pokazuje značajnu povezanost. Pritom je vidljivo kako se razlike u matricama (u pogledu korelacija varijabli s mjerama velepetorih osobina ličnosti) ne očituju isključivo kod intelekta, već kod svih 5 dimenzija ličnosti: u prvom uzorku one su međusobno više povezane nego li u drugom.

Vidljive su i određene dosljednosti u smjerovima i iznosima korelacija značajnih u oba uzorka. Kao prvo, šest statistički značajnih korelacija dobivene su među istim mjerama u oba uzorka. Pet ih je uključivalo neku mjeru BOP-a, a jedan odnos ekstraverzije i emocionalne stabilnosti. Smjer svih značajnih korelacija bio je jednak među uzorcima, a iznosi su bili sličnih vrijednosti. Naime, iznosi su bili (gotovo) jednaki u korelaciji N-BOP-a i OP-BOP-a, OP-BOP-a i OO-BOP-a, te ekstraverzije i emocionalne stabilnosti. S druge strane, najveća razlika koeficijenta korelacije među uzorcima iznosila je 0,2 (za odnos D-2000 i PD-BOP), a najmanja 0,036 (za odnos PD-BOP i OP-BOP). Dakle, kod statistički značajnih korelacija veća je sličnost uočena u smjeru povezanosti, nego li u iznosima.

Kod statistički neznačajnih korelacija proizlazi dodatna sličnost dva uzorka: 23 koeficijenata bila su statistički jednaka nuli u oba uzorka.

Zbirno gledajući, uz šest istovjetnih značajnih korelacija oba uzorka i 23 koje su neznačajne, sveukupno 29 od 45 korelacija - ili 64% - su bile istovjetne u dva promatrana uzorka. Među 16 korelacija koja su se javila u jednom, ali ne i u drugom uzorku, šest su se odnosile na međusobne korelacije osobina ličnosti, pet na korelacije osobina ličnosti i pokazatelje BOP-a, tri na korelaciji neprosječnih pokazatelja BOP-a i g_f i dvije na međusobnoj korelaciji pokazatelja BOP-a.

Korelacije pokazatelja dinamike funkcioniranja BOP-sustava prvog uzorka

Uvidom u rezultate korelacijske analize indikatora dinamike funkcioniranja BOP-sustava uviđa se samo djelomična sličnost nalaza s prvim uzorkom. Ne postoji korelacija

između PD-BOP i N-BOP, što čini bitnu razliku u odnosu na prošli uzorak. Dobivena je negativna, nelinearna i visoka korelacija PD-BOP-a i OP-BOP-a Također je dobivena negativna, linearna i niska korelacija PD-BOP-a i OO-BOP-a. Budući da su rezultati, iako nešto manjih vrijednosti, prilično slični rezultatima prvog uzorka, možemo ponovno utvrditi kako su nalazi tek djelomično očekivani. Očekivani su stoga što je mjera prosječne efikasnosti negativno povezana sa mjerom nestabilnosti, što je logično. Nisu očekivani zato što je opet dobiven nalaz koji pokazuje nelogičan odnos između mjere prosječne efikasnosti BOP sustava i mjere otpornosti na pogreške i omaške, što se ponovno može pojasniti učinkom stropa kod O-BOP-mjera i njihovim asimetričnim raspodjelama.

Povezanost nije dobivena između N-BOP-a i OP-BOP-a (za razliku od prvog uzorka) ali jest dobivena između N-BOP-a i OO-BOP-a kao i u prvom uzorku (visoka nelinearna korelacija). Donekla sličnost u odnosu na prvi uzorak ukazuje na valjanost instrumenata i metodologije istraživanja.

Korelacija između pokazatelja otpornosti na djelovanje nepovoljnih čimbenika je slična kao i u prvom uzorku: radi se o niskoj, pozitivnoj, nelinearnoj korelaciji. Dobivene korelacije još jednom potvrđuju kako ove dvije različite vrste netočnih odgovora dijele tek vrlo mali broj zajedničkih kognitivnih procesa. Dakle, ovaj nalaz potvrđuje valjanost korištenja dva odvojena pokazatelja otpornosti.

Korelacije indikatora BOP-sustava i mjere fluidne inteligencije

Isto kao i u prvom uzorku, g_f i PD-BOP pokazuju pozitivnu linearnu korelaciju, ali je osjetno niža u odnosu na prvi uzorak. Nije dobivena povetanost g_f i N-BOP-a, ali to ne treba čuditi s obzirom na selekcioniranost drugog uzorka, kao i lošoj osjetljivost te asimetričnosti raspodjele N-BOP-a. Iako postoje neke (gore opisane) distinkcije među rezultatima dva uzorka, ti rezultati su općenito slični tako da i u ovom nalazu možemo iščitati argument socio-demografske sličnosti uzoraka i metodološke valjanosti istraživanja.

Odnos g_f s OP-BOP-om i OO-BOP-om je različit od prvog uzorka jer među varijablama u drugom uzorku nije dobivena korelacija. Ovi rezultati nisu u skladu ni s rezultatima prvog uzorka, ni s teorijskim očekivanjima prema kojima su pojedinci veće inteligencije otporniji na djelovanje nepovoljnih čimbenika.

Korelacije pokazatelja BOP-sustava i tri osobine ličnosti

Nije dobivena povezanost između PD-BOP-a i savjesnosti, te PD-BOP-a i intelekta Oba nalaza suprotna su očekivanjima prema kojima su pojedinici s većom brzinom rješavanja manje savjesni, a isto tako je očekivano da pojedinci s većom djelotvornošću BOP-sustavu imaju izraženiji intelekt.

Za razliku od tih nelogičnih rezultata, dobivena je značajna nelinearna korelacija PD-BOP-a i emocionalne stabilnosti, što je očekivano jer oni koji imaju veću prosječnu djelotvornost rješavanja su u prosjeku blago emocionalno stabilniji, što se potvrdilo.

Ni među jedne osobinu ličnosti i N-BOP-a nije dobivena korelacija. Ovi nalazi također nisu u skladu s teorijskim očekivanjima prema kojima bi nestabilnost rješavanja zadataka morala biti negativno povezana s intelektom i emocionalnom stabilnošću.

Slično tome nisu dobivene korelacije između OP-BOP i OO-BOP te tri relevantna čimbenika ličnosti (emocionalna stabilnost, savjesnost i intelekt). I u ovim slučajevima se radi o rezultatima koji odstupaju od očekivanja, prema kojima bi pojedinci koji su otporniji na djelovanje nepovoljnih čimbenika morali imati izraženiji intelekt, emocionalnu stabilnost i savjesnost.