

Suvremena psihologija 12 (2009), 1, 191-199

Pregledni članak - UDK 159.922.27

OBRAZOVNI SUSTAV, INTELIGENCIJA I BOGATSTVO NACIJA – RECIPROČNA UZROČNOST?

Predrag Zarevski i Krunoslav Matešić

Filozofski fakultet, Sveučilište u Zagrebu

I. Lučića 3, 10000 Zagreb

pzarevsk@ffzg.hr, kmatesic@ffzg.hr

Sažetak

Lynn i Vanhaven (2002, 2006) iznijeli su hipotezu da je bogatstvo nacija posljedica razlika u prosječnoj inteligenciji stanovništva. U psihologiji je općeprihvaćena činjenica da inteligentnije osobe imaju veću vjerojatnost da će postići viši obrazovni stupanj, što dovodi, u prosjeku, i do boljih primanja. Je li ova analogija opravdana za slučaj povezivanja prosječnog kvocijenta inteligencije nacija i stupnja nacionalnog bogatstva, predmet je ovog rada.

Ključne riječi: inteligencija, bogatstvo nacija

Koncem prošlog i početkom ovog stoljeća razbuknula se rasprava oko teme koja ima duboke korijene u starom sukobu nativističkih i empirističkih pogleda na inteligenciju. To je intrigantno pitanje, imaju li razlike u bogatstvu nacija neke veze s prosjekom inteligencije i razvijenošću obrazovnog sustava, što je bliže nativističkim teorijama inteligencije, ili je možda obratno, što bi bilo bliže teorijama koje veći naglasak za razvoj inteligencije stavljaju na okolinske utjecaje. Pogledajmo što se sve navodi kao argument za jedan ili drugi stav, pa možda dođemo i do nekog trećeg mogućeg pristupa. Prikaz ove teme uglavnom slijedi kronološki redoslijed pojavljivanja najutjecajnijih radova.

Najčešća mjera bogatstva nacija izražava se kao BDP po glavi stanovnika [napomena: GDP (*Gross domestic product*) odnosno BDP (*Bruto domaći proizvod*) se u Hrvatskoj računa u skladu s Europskim sustavom nacionalnih računa. Mjeri ukupnu vrijednost proizvoda i usluga koje su proizvele rezidencijalne jedinice u promatranom razdoblju (najčešće jednoj godini). Za njegov izračun koristi se jednadžba: ukupna potrošnja + izvoz – uvoz = ukupnoj proizvodnji. GDP p.c. (*per capita*), tj. BDP po glavi stanovnika se dobiva podjelom vrijednosti BDP-a na ukupan broj stanovnika].

Pogledajmo prvo kako je počela rasprava o odnosu bogatstva nacija i inteligencije. U dvije knjige: *IQ and the wealth of nations* iz 2002.g. i *IQ and global inequality* iz 2006.g., Lynn i Vanhanen zastupaju tezu da je bogatstvo nacija posljedica razlika u inteligenciji. Naime, dobro je dokumentirano da inteligentniji pojedinci neke zajednice postižu viši stupanj obrazovanja i profesionalni status, a sve to rezultira većim prosječnim prihodom. Npr. u poznatoj studiji Jencks (1972) nalazi korelaciju između inteligencije i prihoda od 0,31 (korigirano za atenuaciju 0,35) u uzorku bijelaca dobi od 25 do 65 godina iz gradova u SAD-u. U toj su studiji sudjelovali samo muškarci i podaci o inteligenciji i prihodu uzeti su istovremeno. To znači da je možda zbog hipoteze o pozitivnom djelovanju složenijih poslova, koji su ujedno i bolje plaćeni, došlo i do utjecaja prihoda na inteligenciju (po tezi "use it or lose it"). Stoga je Jencks (1979) proveo studiju na 839 muškaraca u dobi od 28 godina, a podatak o inteligenciji je prikupljen kad im je bilo 17 g. Dobivena je korelacija od 0,20, što je objašnjeno time da se u toj dobi još uvijek ne očituju u punom opsegu razlike u prihodu zbog razlika u inteligenciji jer se za najbolje plaćene poslove studira duže i čeka nekoliko godina za postizanje vrhunca karijere. Irwing i Lynn (2006) u Velikoj Britaniji na uzorcima od preko 1000 ispitanika oba spola čiji je IQ izmjeran u dobi od 8 godina, a prihod s 43 godine, kad je uglavnom već postignut vrhunac karijere, nalaze za muškarce korelaciju od 0,38, a kod žena 0,32.

Lynn i Vanhanen (2002, 2006) drže da što vrijedi na razini razlika među pojedincima o odnosu inteligencije i bogatstva, vrijedi i na razini razlika između nacija. Također, u tradiciji evolucionističke psihologije drže da su narodi sa sjevera Europe zbog težih uvjeta preživljavanja nego što su to uvjeti npr. na tropskim otocima, selekcijom najsposobnijih (tj. najinteligentnijih) za preživljavanje, na temelju više inteligencije ostvarili veće bogatstvo nacija. Kao dodatni argument svojoj tezi o okolinskim uvjetima preživljavanja i njihovu utjecaju na inteligenciju, navode hipotezu (Diamond, 1997) da su migracije smjera istok-zapad u Euroaziji bile lakše nego za smjer sjever-jug u ostatku svijeta. To je omogućilo brz transfer znanja i tehnologija između zemalja Euroazije. Naime, te su zajednici imale veći postotak inteligentnih pojedinaca koji su poticali brži tehnološki i znanstveni razvoj, kao i efikasniji obrazovni sustav, što se pozitivno odrazilo na ekonomije zemalja iz umjerenog pojasa Euroazije.

Lynn i Vanhanen (2002) su na temelju procjene IQ-a 81 nacije i njihovu BDP-a po glavi stanovnika došli do koeficijenta determinacije od 0,54. Dodavanjem procjene IQ-a još 101 nacije dobivenih na temelju IQ-a susjednih zemalja, Lynn i Vanhanen (2006) na uzorku od 185 nacija nalaze zajednički postotak inteligencije i bogatstva nacije od 0,39. Dickerson (2006) još izravnije inteligenciji daje status prediktora i umjesto linerne ili kvadratične funkcije, uvođenjem eksponencijalne jednadžbe prediktor inteligencije daje koeficijente determinacije od 0,70 i 0,48 za podatke Lynna i Vanhanena (2002, 2006) za bogatstvo 81, odnosno 185 nacija.

Templer i Arikawa (2006a) nadovezuju se na rad Lynna i Vanhanena (2002, 2006) uvođenjem prosječnih ljetnih i zimskih temperatura, te boje kože u pove-

zanost bogatstva i IQ-a nacija. Nalaze čak i više korelacije između boje kože, za koju drže da je višegeneracijski odraz klime, i IQ-a (0,90), nego IQ-a i BDP-a po glavi stanovnika (0,74). Dakako, Hunt i Sternberg (2006) navode ozbiljne zamjerke kauzalnim interpretacijama rezultata dobivenih na dubioznim podacima. Prvo, drže da testovi razvijeni za srednju američku klasu nisu dobre mjere inteligencije u nekim drugim kulturama. Čak i za tzv. kulturalno nepristrane testove poput Progresivnih matrica sumnjaju da su neovisni o kulturi. Kao argument za to navode *Flynn efekt* koji pokazuje djelovanje kohorte, koje je najlakše objasniti okolinskim utjecajima. O čemu je tu riječ. Politički znanstvenik James R. Flynn s Novog Zelanda objavio je da se u drugoj polovici prošlog stoljeća populacijski IQ u zapadnim zemljama povećava iz generacije u generaciju oko 3 boda IQ-a. Taj je trend do pojave rada Flynna (1984, 1987, 1999) bio zanemaren jer su se norme za IQ testove uvijek određivale za aktualni uzorak iz populacije. Značajne promjene koje su se počele događati početkom druge polovice 20. st. u razvijenim zemljama u sustavu obrazovanja, sve većoj količini informacija kroz sve dostupnije medije, i općenito intelektualno sve poticajnijoj okolini, pojavile su se kao moguć uzrok za Flynn efekt.

Produženo školovanje moglo bi doprinijeti višem IQ-u kod odraslih (Teasdale, Owen, 2000). Npr. Williams (1998) navodi da 1 godina školovanja ima veći efekt i na fluidnu i na kristaliziranu inteligenciju od 1 kronološke godine. Međutim, ovaj faktor ne bi mogao objasniti razlike u IQ-u djece koja su tek ušla u sustav formalnog obrazovanja (kao sedmogodišnjaci), iako su Daley, Whaley, Sigman, Espinosa i Neumann (2003) utvrdili da je u kohorti djece iz 1998. sve veći broj djece koja idu u vrtić te pohađaju nedjeljni vjeronauk. Kao najbolji prediktor veličine Flynn efekta u istraživanju sa švedskom kohortom (Ronnlund, Nilsson, 2008) pokazao se broj godina školovanja. Objasnio je oko 50% varijance efekta koji nisu objasnili ni porast u visini (kao pokazatelj prehranbenog i zdravstvenog napretka) ni broj braće i sestara. Međutim, Flynn efekt je utvrđen i kod djece u dobi 4-6 godina koja imaju vrlo malo edukacije, te čak novorođenčadi (Hanson, Smith, Hume, 1985, prema Lynn, 2007b), što implicira poboljšanje prehrane prenatalno i u ranom postnatalnom razdoblju. No, kad je riječ o predškolskoj djeci, Rabbitt (2007) naglašava da se faktor prehrane ne može uzeti ključnim, a zanemariti npr. stupanj obrazovanja roditelja (i dakako, s njim povezane inteligencije) jer je on posredstvom i genskih i okolinskih faktora povezan s dječjom inteligencijom. Također naglašava da će faktor prehrane biti od većeg značenja u zemljama koje se bore s glađu nego u zapadnom svijetu. Zanimljivo jest da roditelji u Keniji koji očekuju da se u starosti djeca brinu o njima, u većem postotku podržavaju školovanje djece (Daley, Whaley, Sigman, Espinosa, Neumann, 2003). Na koncu Flynn (2000) predlaže objašnjenje po kojem okolinski i socijalni faktori služe kao "pojačivači" određenih kognitivnih vještina, te da bi model recipročne uzročnosti mogao biti najbolje objašnjenje povećanja IQ-a.

Drugo, za Hunta i Sternberga (2006) u radu Templera i Arikawe (2006a) vrlo je upitan kriterij *dominantne boje kože* – možda vrijedi za neku otočnu zemlju sa 100.000 stanovnika, ali što je s multietničkim zemljama poput Kine ili Indije. Nad-

alje se pitaju koliko taj kriterij danas vrijedi i za nekad dominantno bjelačke zemlje poput Velike Britanije, Francuske ili Njemačke. Upitno je i što uzeti za prosjek IQ-a SAD-a, koji pokazuje znatne razlike između saveznih država. Zamjerka koja se odnosi na rad Lynna i Vanhanena (2002, 2006), a Templer i Arikawa (2006a) koriste i dio njihovih podataka, jest da uzorci za procjenu IQ-a nacija uglavnom nisu bili reprezentativni, a neki su bili vrlo mali. Zaključuju da je previše teorijskih i metodoloških propusta da bi se povezanost prosječnih ljetnih i zimskih temperatura, boje kože, bogatstva i IQ-a nacija moglo dovesti u uzročno-posljedični odnos. Templer i Arikawa (2006b) u obranu svojih nalaza i nalaza Lynna i Vanhanena navode da je teško dobiti korelacije reda veličine 0,70–0,90 na nevaljanim podacima korištenjem nevaljanih statističko-matematičkih postupaka.

Kanazawa (2006) je, koristeći metodologiju Lynna i Vanhanena, izračunao povezanost BDP-a saveznih država u SAD-u s rezultatima na SAT-u (napomena: *Scholastic Assessment Test* [SAT] je razvijen da maksimizira prediktabilnost akademskog uspjeha, a minimizira potencijalne vanjske faktore poput spolne, etničke ili socijalne pristranosti. Premda je mjera akademskog postignuća, dobra je aproksimacija *g*-a inteligencije očitovanog kroz sposobnosti koje se razvijaju školovanjem. Naime, visoko korelira s *g*-om ekstrahiranim iz baterija testova inteligencije namijenjenih mjerenju *g*-a). Nalazi da se oko 1/3 bogatstva saveznih država može objasniti pomoću prosječnog uspjeha na SAT-u. McDaniel (2006) poboljšanom metodologijom procjene IQ-a saveznih država SAD-a potvrđuje da što je viša procjena inteligencije, država ima veći BDP, prosječni prihod i manji postotak populacije koji živi u siromaštvu.

Nakon dosta kritika na teze iznesene u dvije knjige o IQ-u i bogatstvu nacija, u potrazi za objektivnijom mjerom kognitivnog potencijala nacija, Lynn i Mikk (2007) uvode varijablu akademskog postignuća u povezanost inteligencije i bogatstva nacija jer je neosporna povezanost inteligencije i akademskog postignuća na razini interindividualnih razlika. Koeficijenti korelacije između opće inteligencije i školskih ocjena u osnovnoj školi iznose u prosjeku oko 0,50 (Jensen, 1980; Neisser i sur., 1996). Ta korelacija se smanjuje u srednjim školama i još je niža na sveučilišnoj razini (npr. Jensen, 1980, Matešić i Zarevski, 2008), a sve je značajnija uloga ličnosti (npr. Bratko, Chamorro-Premuzic i Saks, 2006; Chamorro-Premuzic i Artech, 2008).

Autori poput Blooma (1976) ili Glasera (1977) smatraju da su testovi inteligencije prediktivni samo za školski uspjeh u monolitnim edukacijskim sustavima. Kad bi osigurali adaptivan i individualiziran školski program za svako dijete, ta bi korelacija bila znatno umanjena. U tom bi slučaju trebalo razviti specijalizirane testove za pojedine kriterije školskog postignuća, osobito u smislu do koje je razine dijete savladalo određeni sadržaj i kad je spremno za usvajanje složenijeg sadržaja.

Lynn i Mikk (2007) kreću od teze da se “mentalni potencijal” nacije očituje i u rezultatima na testovima inteligencije i na objektivnim mjerama akademskog postignuća poput onih u TIMSS studiji 2003 (Mullis, Martin, Gonzalez i Chrostowski,

2004). Tom studijom su obuhvaćeni reprezentativni uzorci 10-godišnjaka iz 25 zemalja i 14-godišnjaka iz 46 zemalja prosječne veličine uzoraka od nešto manje od 5.000 sudionika (minimum je bio 2980 a maksimum 9829 sudionika). Ispitano je znanje iz matematike i prirodnih znanosti u 3 kognitivne domene: činjenično znanje, pojmovno razumijevanje, te rezoniranje i analiziranje. Lynn i Mikk (2007) navode da se od 1960-ih nalaze dosta konzistentne razlike u uspjehu učenika iz matematike i prirodnih znanosti među nacijama. Prednjače kineski, japanski i korejski učenici, slijede ih europski, a najslabiji su rezultati u zemljama u razvoju. Kao objašnjenje za taj nalaz navedeni su razlozi poput sredstava koja se izdvajaju za školstvo, veličine razreda, kvalificiranosti učitelja i sl. Međutim, kao potencijalni razlog za razlike u školskom postignuću među nacijama nije uzimana u obzir razlika u prosjecima inteligencije jer tog podatka do rada Lynna i Vanhanena (2002, 2006) nije bilo. U svom su istraživanju Lynn i Mikk (2007) ispitali povezanost između IQ-a, BDP-a, ukupnog rezultata na TIMSS-u, te niza sociodemografskih i edukacijskih varijabli. Pokazalo se da ukupni uspjeh u matematici i prirodnim znanostima 14-godišnjaka korelira s IQ-om nacija 0,91, a BDP-om 0,55. Varijable veličina razreda, kvalificiranost učitelja, posjedovanje vlastitog radnog stola, sigurnost školskog okruženja, obrazovanost roditelja, očekivana životna dob koreliraju vrlo slično u rasponu od 0,31 do 0,75 s rezultatom na TIMSS-u i IQ-om. Međutim, regresijska je analiza pokazala da je za predikciju akademskog postignuća dovoljna varijabla IQ-a. Premda su ostale varijable umjereno do visoko korelirane s rezultatom na TIMSS-u, kad se parcijalizira IQ ni jedna od sociodemografskih i edukacijskih varijabli više nema značajni beta-ponder. Povezanost inteligencije i rezultata u matematici bila je 0,87 i 0,92 za 10- i 14-godišnjake respektivno. Slično je dobiveno i za rezultat u prirodnim znanostima: 0,85 i 0,91 za ta dva dobna uzorka. Time je jasno pokazana vrlo visoka povezanost inteligencije i školskog postignuća u usporedbi uzoraka od 25, odnosno 46 nacija.

U interpretaciji dobivenih rezultata Lynn i Mikk (2007) kreću od tri hipoteze koje postavljaju Luo, Thompson i Detterman (2003) za objašnjenje povezanost inteligencije i školskog postignuća. Prva kaže da je inteligencija uzrok razlika u školskom postignuću jer je biološki više uvjetovana od školskog postignuća (npr. Jensen, 1998b). Po drugoj hipotezi je inteligencija djelomično produkt procesa školovanja (npr. Ceci, 1991). A treća hipoteza kaže da su i inteligencija mjerena testovima i školsko postignuće djelomično determinirane temeljnim kognitivnim procesima poput vremena reakcije i inspekcije (IT) i mjerama funkcioniranja pamćenja. Luo, Thompson i Detterman (2003) drže da za djecu od 6 do 13 godina ima najviše empirijske podrške za treću hipotezu. Lynn i Mikk te teze s razine interindividualnih razlika postavljaju na razinu razlika među nacijama. U prethodnim su radovima Lynn i Vanhanen (2002, 2006) bili skloni prvoj hipotezi o genski uvjetovanim razlikama u inteligenciji među pripadnicima različitih nacija koja je odredila bogatstvo nacija, odnosno u ovom bi slučaju bila uzrokom razlika u školskom postignuću među nacijama. Lynn i Mikk (2007) nalaze dovoljno razloga da podrže sve tri navedene

hipoteze koje iznose Luo, Thompson i Detterman i ponude kompromisno rješenje u obliku *recipročne uvjetovanosti* nacionalnih IQ-a, mjera školskog postignuća i bogatstva koja se temelji na složenoj mreži povezanosti. O čemu je riječ? Viša prosječna inteligencija nacije osigurava veći BDP jer inteligentniji pojedinci mogu zaraditi više. Istodobno, viši BDP ima pozitivan recipročni efekt na prosječni IQ nacije, jer više novca može biti odvojeno za kvalitetnu prehranu, obrazovni i zdravstveni sustav, a te varijable imaju jaku pozitivnu povezanost s inteligencijom.

Rindermann (2007a,b) zbog pozitivnog skupa korelacija između nacionalnih IQ-a i rezultata na testovima akademskog postignuća uvodi pojam velikog G-faktora razlika u nacionalnim kognitivnim sposobnostima. Rindermann (2008) također koristi podatke Lynna i Vanhanena (2002, 2006) o nacionalnim kvocijentima inteligencije i mjere iz TIMSS studije 2003, ali i ostalih međunarodnih procjena akademskog postignuća (PISA-2000/OECD, 2003/; PISA-2003/(OECD, 2004a, 2004b/; TIMSS 2003/Mullis i sur., 2004); IEA-Reading-Study/Elley, 1992/; PIRLS 2001/Mullis, Martin, Gonzalez, Kennedy, 2003/) za utvrđivanje njihove povezanosti s bogatstvom nacija. Složenim matematičkim analizama u longitudinalno koncipiranom pristupu dolazi do nekoliko zaključaka. Potvrđuje jaku povezanost kognitivne i edukacijske razine od 0,73 za uzorak od 173 zemlje. Inteligencija i akademsko postignuće imaju jači utjecaj na ekonomsko blagostanje nego što je to obrnuto, premda je ekonomska moć zemlje za kognitivni razvoj populacije vrlo važna.

Na koncu treba istaknuti, da unatoč činjenici kako tema o uzrocima bogatstva nacija ima u sebi natruhe rasističkih i elitističkih stavova, poruka koju šalje Richard Lynn u svojim radovima (a imali smo priliku i osobno o tome raspravljati s njim) jest da empirijski nalazi upućuju na to *da dokle god se ne poprave edukacijske, zdravstvene i prehrambene prilike u nerazvijenim zemljama i zemljama u razvoju*, njihovi će stanovnici zaostajati u inteligenciji za razvijenim zemljama i to će se odražavati na bogatstvo tih nacija. A onda kreće negativan začarani krug *recipročne uvjetovanosti* koji ne dopušta da se poveća prosječni IQ, koji bi pokrenuo naciju u smjeru većeg BDP-a. Nažalost, što vrijedi za odnos IQ-a, obrazovnih, zdravstvenih prilika i bogatstva među nacijama, vrijedi i za pripadnike najsiromašnijih slojeva bogatih zemalja...

LITERATURA

- Bloom, B.S. (1976). *Human characteristics and school learning*. New York, NY: McGraw-Hill.
- Bratko D., Chamorro-Premuzic T., Saks Z., (2006). Personality and school performance: Incremental validity of self- and peer-ratings over intelligence, *Personality and Individual Differences*, 41, 131–142.
- Ceci, S.J. (1991). How much does schooling influence general intelligence and its cognitive components? *Developmental Psychology*, 27, 703-722.

- Chamorro-Premuzic, T., Arteche, A. (2008). Intellectual competence and academic performance: Preliminary validation of a model. *Intelligence*, 36, 564-573.
- Daley, T.C., Whaley, S.E., Sigman, M.D., Espinosa, M.P., Neumann, C. (2003). IQ on the rise: The Flynn Effect in rural Kenyan children. *Psychological Science*, 14, 215-219.
- Diamond, J. (1997). *Guns, germs and steel: The fates of human societies*. New York: W.W. Norton.
- Dickerson, R.E. (2006). Exponential correlation of IQ and the wealth of nations. *Intelligence*, 34, 291-295.
- Elley, W.B. (1992). *How in the world do students read?* The Hague: The International Association for the Evaluation of Educational Achievement (IEA).
- Flynn, J.R. (1984). The mean IQ of Americans: Massive gains 1932 to 1978. *Psychological Bulletin*, 95, 29-51.
- Flynn, J.R. (1987). Massive IQ gains in 14 nations: What IQ tests really measure. *Psychological Bulletin*, 101, 171-191.
- Flynn, J.R. (1999). Searching for justice: The discovery of IQ gains over time. *American Psychologist*, 54, 5-20.
- Flynn, J.R. (2000). IQ gains, WISC subtests, and fluid *g*: *g* theory and the relevance of Spearman's hypothesis to race. In G.R. Bock, J.A. Goode (Eds.), *The nature of intelligence*, pp. 202-227. New York: Wiley.
- Glaser, R. (1977). *Adaptive education: Individual diversity and learning*. New York, NY: Holt, Rinehart and Winston.
- Hunt, E., Sternberg, R.J. (2006). Sorry, wrong numbers: An analysis of a study of a correlation between skin color and IQ. *Intelligence*, 34, 131-137.
- Irwing, P., Lynn, R. (2006). The Relation Between Childhood IQ and Income in Middle Age. *Journal of Social, Political and Economic Studies*, 31, 191-196.
- Jencks, C. (1972). *Inequality*. London: Penguin.
- Jencks, C. (1979). *Who Gets Ahead*. New York: Basic Books
- Jensen, A. (1980). *Bias in mental testing*. New York: Free Press.
- Jensen, A. (1998). *The g factor*. Westport: Praeger.
- Kanazawa, S. (2006). IQ and the wealth of states. *Intelligence*, 34, 593-600.
- Luo, D., Thompson, L. A., Detterman, D. (2003). The casual factor underlying the correlation between psychometric and scholastic performance. *Intelligence*, 31, 67-83.
- Lynn, R. (2007b). Nutrition and IQ. *Psychologist*, 20, 471-472.
- Lynn, R., Vanhanen, T. (2002). *IQ and the Wealth of Nations*. Westport, Connecticut: Praeger.
- Lynn, R., Vanhanen, T. (2006). *IQ and global inequality*. Augusta, Georgia: Washington Summit Publishers.
- Lynn, R., Mikk, J. (2007). National differences in intelligence and educational attainment. *Intelligence*, 35, 115-121.
- Matešić, K. ml., Zarevski, P. (2008). Correlation between intelligence and dimensions of personality and school success. *Metodika*, 9, 366-379.
- McDaniel, M.A. (2006). Estimating state IQ: Measurement challenges and preliminary correlates, *Intelligence*, 34, 607-619.

- Mullis, I.V.S., Martin, M.O., Gonzalez, E.J., Chrostowski, S.J. (2004). TIMSS 2003 international mathematics report. Chestnut Hill: TIMSS and PIRLS International Study Center.
- Neisser, U., Boodoo, G., Bouchard, T.J., Boykin, A.W. Jr., Brody, N., Ceci, S.J., Halpern, D.E., Loehlin, J.C., Perloff, R., Sternberg, R.J., Urbina, S. (1996). Intelligence: Knowns and unknowns. *American Psychologist*, 51, 77–101.
- OECD (2000). *Literacy in the information age*. Final report of the International Adult Literacy Survey. Paris: OECD.
- OECD (2003). *Literacy skills for the world of tomorrow*. Further results from PISA 2000. Paris: OECD.
- OECD (2004a). *Learning for tomorrow's world*. First results from PISA 2003. Paris: OECD.
- OECD (2004b). *Problem solving for tomorrow's world*. Paris: OECD.
- OECD (Adams, R., Wu, M.). (2002). *PISA 2000 technical report*. Paris: OECD.
- Rabbitt, P. (2007). IQ – The meek approach is best. *Psychologist*, 20, 532.
- Rindermann, H. (2007a). The g-factor of international cognitive ability comparison: The homogeneity of results in PISA, TIMSS, PIRLS and IQ-tests. *European Journal of Personality*, 21, 667–706.
- Rindermann, H. (2007b). Author's Response. The Big G-factor of national cognitive ability. *European Journal of Personality*, 21, 767–787.
- Rindermann, H. (2008). Relevance of education and intelligence at the national level for the economic welfare of people, *Intelligence*, 36, 127-142.
- Ronnlund, M., Nilsson, L.G. (2008). The magnitude, generality, and determinants of Flynn effects on forms of declarative memory and visuospatial ability: Time-sequential analyses of data from Swedish cohort study. *Intelligence*, 36, 192-209.
- Teasdale, T.W., Owen, D.R. (2008). Secular declines in cognitive test scores: A reversal of the Flynn Effect. *Intelligence*, 36, 121-126.
- Templer, D.I., Arikawa, H. (2006a). Temperature, skin color, per capita income, and IQ: An international perspective. *Intelligence*, 34, 121-139.
- Templer, D.I., Arikawa, H. (2006b). The Jensen and the Hunt and Sternberg comments: From penetrating to absurd. *Intelligence*, 34, 137-139.
- Williams, W. (1998). Are we raising smarter children today? School and home related influences on IQ. In U. Neisser (Ed.), *The rising curve: Long-term gains in IQ and related measures* (pp. 125–154). Washington, DC: American Psychological Association.

EDUCATIONAL SYSTEM, INTELLIGENCE AND WEALTH
OF NATIONS – RECIPROCAL CAUSALITY?

Abstract

Lynn and Vanhaven (2002, 2006) hypothesized that the wealth of nations is a consequence of differences in the average intelligence of the population. It is generally accepted in psychology that persons of higher intelligence will more likely achieve a higher level of education which, in turn, leads to higher earnings. Is this analogy justified in connecting the average intelligence quotient of a nation with the degree of wealth is the subject of the present paper.

Key words: intelligence, wealth of nations

Primljeno: 26. 02. 2009.