

UDK: 37.014

37.012

Izvorni znanstveni rad

Primljeno 28.2.2019.

Suvremeni modeli i pristupi analizi podataka u obrazovnim istraživanjima

Toni BABAROVIĆ

Institut društvenih znanosti Ivo Pilar, Zagreb, Hrvatska

toni.babarovic@pilar.hr

Sažetak

Današnja se istraživanja u području obrazovanja zasnivaju na upotrebi odgovarajućih pristupa prikupljanju podataka te suvremenim modelima njihove analize. Metodološki su iskoraci u ovom području znatni, a istraživači u posljednjih nekoliko desetljeća prepoznaju važnost primjene longitudinalnih nacrta u obrazovnim istraživanjima. Također, uviđanje hijerarhijske organizacije prikupljenih podataka i njihova odgovarajuća statistička obrada postaju metodološki imperativ. U ovom je radu pružen metodološki pregled hijerarhijske i longitudinalne organizacije podataka te teorijski okvir njihove statističke analize. Istaknute su najčešće pogreške i poteškoće s kojima se istraživači prilikom korištenja ovih metoda susreću te načini kako ih ispravno prevladati. Kroz jednostavne i svakodnevne primjere pokušalo se čitatelju približiti ove metode i njihovu statističku podlogu te uputiti istraživače u području obrazovnih istraživanja na njihovo adekvatno korištenje.

Ključne riječi: *hijerarhijski modeli; longitudinalni nacrti; analiza podataka; obrazovna istraživanja; statistika*

1. Uvod

Od devedesetih godina prošlog stoljeća istraživanja u području obrazovanja znatno su napredovala u pogledu njihovih istraživačkih nacrta, primjenjenih metoda uzorkovanja te upotrebe naprednijih statističkih metoda. Takav metodološki napredak omogućio je točniju procjenu učinka obilježja učitelja i škola na postignuće učenika. Danas se svi istraživači u području obrazovnih znanosti slažu da postoje dva metodološka imperativa: prikupljanje longitudinalnih podataka i prepoznavanje hijerarhijske organizacije prikupljenih podataka (Creemers i Kyriakides, 2007). Evidentan razlog tomu je činjenica da su prikupljeni podaci dinamičke prirode, odnosno da se mijenjaju kroz vrijeme. Uvažavanje njihove dinamičke prirode je ključno, jer učinci škola trajno mijenjaju obrazovni razvoj učenika, a sama obilježja učenika, učitelja i školske okoline su promjenjiva. Zato je prikupljanje longitudinalnih podataka (u nekoliko vremenskih točaka) nužno da bi se mogli utvrditi točni učinci učitelja i škola na obrazovna postignuća učenika. S druge strane, promatrane i mjerene pojave nužno se pojavljuju u višerazinskoj, hijerarhijskoj strukturi. Podaci o obilježjima škola prikupljeni su na jednoj razini, podaci o obilježjima učitelja na drugoj, dok su podaci o učeničkom uspjehu prikupljeni na trećoj, najnižoj razini. Dakle, prisutna je višerazinska, hijerarhijska struktura prikupljenih podataka jer je sve učenike jednog razreda poučavao isti učitelj, a svi su učenici, a i učitelji jedne škole, izloženi istoj školskoj okolini te dijele ista, školska obilježja. Očita hijerarhijska organizacija podataka zahtijeva specifične statističke analize koje omogućavaju utvrđivanje obrazovnih ishoda mjerenih na više razina.

2. Hijerarhijski (višerazinski) modeli

U istraživanjima obrazovanja postoji nezaobilazna hijerarhijska organizacija podataka. Učenici žive, uče i pohađaju nastavu u određenoj organizacijskoj strukturi. To je hijerarhijski definirana socijalna struktura koja uključuje obitelj, vršnjačku grupu, razredni odjel, školu, općinu, regiju, pa na kraju i državu. Takva višerazinska organizacija podataka uzrokuje nekoliko specifičnih problema kod njihove statističke analize.

Učenici koji djeluju unutar hijerarhijski organiziranih jedinica po svojim su osobinama međusobno znatno sličniji negoli su to slučajno odabrani učenici iz različitih skupina. Primjerice, učenici nekog razrednog odjela petog razreda međusobno su mnogo sličniji nego slučajno odabrani učenici petih razreda na razini grada, županije ili države. Razlog tome je što učenici tog konkretnog petog razreda nisu slučajno odabrani iz cjelokupne populacije i slučajno upisani baš u taj razred. Oni potječu iz istih, geografski određenih jedinica. Oni su iz iste regije, istog grada ili kvarta i po tome su mnogo homogeniji po nizu varijabli. Vjerojatno su homogeniji po socio-ekonomskom statusu (SES-u), etničkoj pripadnosti, obiteljskom nasljeđu ili pripadnosti određenoj religiji nego učenici petih razreda u cijeloj promatranoj populaciji. Nadalje, učenici tog konkretnog razrednog odjela dijele zajedničku školsku okolinu, iste učitelje, razred ili školu, sa svim njihovim fizičkim i organizacijskim obilježjima. To rezultira sličnim iskustvima i dovodi do dodatne homogenizacije tijekom vremena.

Kako se adekvatno nositi s problemom hijerarhijske organizacije podataka? U istraživanjima koja se bave učinkovitostšću obrazovanja nakana istraživača je utvrditi kako učiteljeva obilježja i škola, utječu na školski uspjeh uz kontrolu pozadinskih varijabli, poput SES-a obitelji, spola ili ranijeg obrazovnog uspjeha. Najčešće su uspjeh učenika i obilježja njegove obitelji prikupljeni na razini učenika, a ostali podaci na razini razrednog odjela, razreda, učitelja, škole, grada ili regije. Postavlja se pitanje - *Što je adekvatna jedinica analize – učenik, razred, škola, grad ili možda regija?*

Jedna od mogućih strategija je da se sva obilježja razreda, učitelja ili škole svedu na razinu učenika, odnosno da se podaci s više razine svedu na nižu analitičku razinu. Dakle, radi se o postupku disagregacije varijabli s više hijerarhijske razine na onu nižu. Tako bi svi učenici konkretnog petog razreda u varijabli veličina razreda dobili istu vrijednost, npr. 25 učenika u razredu, ili bi na razini staža učitelja Matematike svi dobili 8 godina radnog staža. Problem ovakvog pristupa je nepostojanje nezavisnosti opažanja, jer svi učenici jednog razreda imaju identične rezultate na navedenim varijablama. Nezavisnost opažanja je jedan od prvih preduvjeta nepristrane i točne statističke analize i podrazumijeva međusobnu nezavisnost sudionika odabranih u istraživanje. Kao što je navedeno, odabrani učenici nekog razreda nisu potpuno nezavisne jedinke

već dijele istu školsku okolinu te imaju donekle slična demografska i obiteljska obilježja. Dakle, u hijerarhijski organiziranim podacima pretpostavka o nezavisnosti jedinki u uzorku je nužno narušena, a sudionici su dodatno homogenizirani. Zato je u analizama u kojima je provedena disagregacija varijabli više razine na razinu učenika standardna pogreška mjerjenja znatno podcijenjena, odnosno manja no što bi bila da se radi o nehijerarhijskom ili uzorku potpuno slučajno odabranih učenika. To se najbolje može ilustrirati *napuhanom* veličinom uzorka za pojedino disagregirano svojstvo koje ulazi u analizu. Naime, ranije navedena veličina razreda nije osobina učenika, već razreda i u uzorku se pojavljuje onoliko puta koliko ima razreda. Disagregacijom se povećava broj opažanja te osobine na onoliko koliko ima učenika, a taj je broj nekoliko puta veći. Time se smanjuje procjena varijance pogreške, što posljedično dovodi do veće vjerojatnosti neopravdanog odbacivanja nul-hipoteze i liberalnijeg zaključka o značajnosti predikcije (Osborne, 2000). Drugim riječima, tim postupkom istraživači dolaze do statistički značajnih razlika koje su potpuno netočne (Hox, 2010).

Drugi je pristup sažimanje podataka na razinu razrednog odjela, razreda, škole, grada, ili županije, dakle, *prebacivanje* podataka s niže razine na onu višu. Riječ je o agregaciji rezultata na nekoj varijabli mjerenoj na nižoj razini na višu razinu analize. Tako bi se mogao, na primjer, ispitivati utjecaj prosječnog SES-a roditelja (agregiran s individualne na neku višu razinu) na uspjeh razreda, škole ili županije. Ovaj pristup vezuje uz sebe nekoliko problema. Najvažniji je da je na taj način izgubljen ogroman varijabilitet zavisne varijable, odnosno uspjeh učenika je uvijek uprosječen na nekoj višoj razini. Takvo smanjenje varijabiliteta može dovesti do velikog podcenjivanja ili pak precjenjivanja koreacijskog odnosa među promatranim varijablama (Bryk i Raudenbush, 1992), a nužno dovodi do smanjenja statističke snage provedene analize (Hox, 2010).

Osim navedenih statističkih pogrešaka, oba pristupa također mogu dovesti do krivih konceptualnih i logički pogrešnih zaključka. Može se dogoditi da istraživač proveđe analizu na jednoj razini podataka, a donese zaključak na drugoj razini. Najpoznatija pogreška tog tipa je takozvana ekološka pogreška (eng. *ecological fallacy*) do koje dolazi kada se podaci agregirani i analizirani na nekoj višoj razini interpretiraju na individualnoj

razini. S obzirom na to da se agregacijom značenje varijabli sadržajno i suštinski mijenja ne može se više govoriti o tome što je povezano s uspjehom učenika, već što je eventualno povezano s obrazovnim uspjehom razreda, škole ili županije. S druge strane, disagregacijom rezultata s više razine (npr. razine škole) na nižu razinu (npr. razinu učenika) i interpretiranjem tih razlika kao razlika među grupama ulazi se u pogrešku poznatu kao atomistička pogreška (eng. *atomistic fallacy*).

Iz navedenog je vidljivo da svođenje višerazinskih podataka na samo jedu razinu analize (bilo onu višu ili nižu) nosi sa sobom niz evidentnih statističkih pogrešaka, a potencijalno vodi i u moguće pogreške logičkog zaključka. Zato su razvijeni adekvatni statistički postupci koji uključuju varijable različitih razina u jedinstvenu statističku analizu bez gubitka informacija o originalnoj razini mjerjenja pojedinog svojstva. Te se analize nazivaju Višerazinskim analizama (eng. *Multilevel Analysis*; Hox, 2010), Višerazinskim modeliranjem (eng. *Multilevel Modeling*; Luyten i Sammons, 2010), Modelima slučajnih koeficijenata (eng. *Random Coefficients Models*; de Leeuw i Kreft, 1986) ili Hijerarhijskim linearnim modeliranjem (eng. *Hierarchical Linear Modeling – HLM*; Raudenbush i Bryk, 2002). Takvi postupci omogućavaju ispitivanje istraživačkih hipoteza koje su postavljene između više razina, odnosno pružaju odgovor na višerazinske probleme. Pod višerazinskim problemima podrazumijeva se utvrđivanje odnosa među varijablama koje su mjerene na različitim hijerarhijskim razinama. Tako je u obrazovnim istraživanjima ključno pitanje kako niz varijabli mjerentih na individualnom (npr. SES obitelji, spol učenika, ranija razina znanja) i grupnom novou (npr. staž učitelja, veličina razreda, opremljenost škole) utječe na jednu kriterijsku varijablu na individualnom nivou (npr. znanje učenika). Višerazinskim analizama može se utvrditi izravan utjecaj varijabli mjerentih na različitim nivoima na kriterijsku mjeru, ali se i dodatno može utvrditi postaje li neka varijabla s grupnog nivoa moderator odnosa prediktora i kriterija mjerentih na individualnom nivou.

3. Metode višerazinske analize podataka

Osnovni statistički koncept na kojem počivaju hijerarhijski linearni modeli (HLM) je klasična linearna regresija koja je modificirana

za upotrebu na hijerarhijski organiziranim podacima. Kao što je rečeno, hijerarhijski organizirani podaci imaju više razina. Najniža razina (obično nazvana razina – 1) je razina učenika, druga razina (razina – 2) može biti razina razreda, treća razina (razina – 3) razina škole, i tako dalje. Ovdje ćemo za početak razraditi primjer dvorazinske strukture u kojoj su učenici ugniježđeni u školske razrede. Na prvoj razini, odnosno koristeći samo osobine učenika, možemo definirati jednostavnu regresijsku jednadžbu prognoze uspjeha učenika kao:

$$Y_{ij} = b_{0j} + b_{1j}X_{1ij} + \dots + b_{kj}X_{kij} + e_{ij}$$

gdje je Y_{ij} uspjeh učenika koji pripada nekoj grupi j ; b_{0j} je konstanta (intercept, odsječak na osi Y) za grupu j ; b_{1j} je regresijski koeficijent grupe j (koeficijent smjera pravca) za promatranoj varijablu X_1 ; dok je e_{ij} rezidual (pogreška prognoze) za pojedinca i iz grupe j .

Tako u nekom primjeru možemo prognozirati uspjeh učenika (i) iz Matematike koji pohađa razred (j) na temelju njegova spola (varijabla X_1) i njegove motivacije za učenje matematike (X_2). Tada bi regresijska jednadžba izgledala ovako:

$$\text{mat}_{ij} = b_{0j} + b_{1j} \text{spol}_{ij} + b_{2j} \text{motiv}_{ij} + e_{ij}$$

Razlika između ovako postavljene regresijske jednadžbe i obične regresijske jednadžbe (eng. *Ordinary Least Squares - OLS*) je postojanje indeksa (j) koji govori o pripadnosti učenika nekom razredu. Time se podrazumijeva da pojedini razredi mogu imati različite intercepte (b_{0j}) i različite koeficijente nagiba pravca prognoze (b_{1j} ili b_{2j}). S obzirom na to da su intercepti i koeficijenti pravca slučajne variable koje slobodno variraju od razreda do razreda nazivaju se *slučajni koeficijenti* (eng. *random coefficients*). Ako se vratimo na naš primjer, razredi koji imaju veći intercept imaju i veći prosječni učenički uspjeh iz Matematike. Ako pojedini razredi imaju veće regresijske koeficijente (koeficijente nagiba pravca) u tim je razredima povezanost između spola¹, odnosno motivacije i uspjeha u Matematici veća.

¹ U ovom se korelacijskom kontekstu govori o povezanosti između spola i uspjeha u matematici, a suštinski se misli na spolne razlike u uspjehu iz matematike

Ako promatramo sve razrede uključene u analizu prepostavlja se da je distribucija regresijskih koeficijenata približno normalna². Stoga je drugi korak hijerarhijskog regresijskog modela objasniti varijabilitet tih regresijskih koeficijenata koristeći varijable izmjerene na drugoj razini, odnosno razini razreda. Dakle, na drugoj razini, u HLM-u, konstanta (intercept) i koeficijent smjera pravca iz prve razine postaju kriteriji, a njihove se vrijednosti pokušavaju predvidjeti na osnovi rezultata varijabli druge razine, odnosno izraženo jednadžbama, glasi:

Za intercept:

$$b_{0j} = \gamma_{00} + \gamma_{01}W_j + \dots + \gamma_{0k}W_k + u_{0j}$$

Za regresijske koeficijente:

$$b_{1j} = \gamma_{10} + \gamma_{11}W_j + \dots + \gamma_{1k}W_k + u_{1j}$$

$$b_{2j} = \gamma_{20} + \gamma_{21}W_j + \dots + \gamma_{2k}W_k + u_{2j} \quad \text{itd.}$$

gdje su γ_{00} i γ_{10} konstante (intercepti); γ_{01} i γ_{11} predstavljaju regresijske koeficijente (koeficijente smjera pravca) u predviđanju b_0 i b_1 na osnovi varijable druge razine W_j ; dok u_{0j} i u_{1j} predstavljaju pogreške prognoze.

Da bismo pojasnili značenje navedenih jednadžbi, možemo se poslužiti ranijim primjerom. Zamislimo da na razini razreda (druga razina) imamo varijablu veličine razreda. Prva jednadžba u kojoj se predviđa b_0 govori o uspješnosti predikcije razlike u prosječnom uspjehu iz Matematike pojedinih razreda na osnovi veličine razreda. Dakle, ako varijabla druge razine može dobro objasniti ovako definiran kriterij (ako je γ_{01} značajan), to znači da se razredi razlikuju po uspjehu upravo zbog razlike u svojoj veličini.

Drugi set jednadžbi govori o moderatorskom efektu varijabli druge razine na uspješnost prognoze učeničkog uspjeha na osnovi varijabli prve razine. U terminima analize varijance ta nam jednadžba govori o interakciji varijabli dvaju promatranih razina na uspjeh. U prvom primjeru radi se o interakciji spola učenika s prve razine i veličine razreda s druge razine na uspjeh iz Matematike. U drugom slučaju, kako imamo dvije prediktorske varijable prve razine, radi se o interakcijskom učinku motivacije učenika i

² Više o načinima testiranja preduvjeta za provedbu hijerarhijskih regresijskih modela može se pronaći u Goldstein (2003) te Snijders i Bosker (1999).

veličine razreda na školski uspjeh iz Matematike. Ako je γ_{11} značajan može se zaključiti da se utjecaj spola na uspjeh učenika mijenja ovisno o veličini razreda, odnosno da spolne razlike u uspjehu značajno variraju ovisno o veličini razreda. Ako je regresijski koeficijent iz druge jednadžbe γ_{21} značajan može se zaključiti da se utjecaj učeničke motivacije na školski uspjeh mijenja ovisno o veličini razreda. Drugim riječima, u razredima različite veličine, utjecaj motivacije na školski uspjeh iz Matematike nije isti.

Na kraju, primjer dvorazinskog modela u kojem postoje dvije prediktorske varijable mjerene na razini učenika (spol i motivacija) te jedna mjerena na razini razreda (veličina razreda) može se izraziti jedinstvenom složenom regresijskom jednadžbom koja integrira ranije navedene:

$$Y_{ij} = \gamma_{00} + \gamma_{10}X_{1ij} + \gamma_{20}X_{2ij} + \gamma_{01}W_j + \gamma_{11}X_{1ij}W_j + \gamma_{21}X_{2ij}W_j + u_{1j}X_{1ij} + u_{2j}X_{2ij} + u_{0j} + e_{ij}$$

Ili, ako koristimo sadržajna imena varijabli:

$$\text{mat}_{ij} = \gamma_{00} + \gamma_{10}\text{spol}_{ij} + \gamma_{20}\text{motiv}_{ij} + \gamma_{01}\text{vel}_j + \gamma_{11}\text{spol}_{ij} \times \text{vel}_j + \gamma_{21}\text{motiv}_{ij} \times \text{vel}_j + u_{1j}\text{spol}_{ij} + u_{2j}\text{motiv}_{ij} + u_{0j} + e_{ij}$$

Prvi dio jednadžbe $[\gamma_{00} + \gamma_{10}X_{1ij} + \gamma_{20}X_{2ij} + \gamma_{01}W_j + \gamma_{11}X_{1ij}W_j + \gamma_{21}X_{2ij}W_j]$ sadrži fiksne koeficijente i naziva se fiksnim ili determinističkim dijelom modela. Drugi dio jednadžbe $[u_{1j}X_{1ij} + u_{2j}X_{2ij} + u_{0j} + e_{ij}]$ sadrži slučajne pogreške i naziva se slučajnim ili stohastičkim dijelom modela. Izrazi $\gamma_{11}X_{1ij}W_j$ i $\gamma_{21}X_{2ij}W_j$ odnose se na interakciju među varijablama dvaju razina, odnosno na moderatorski utjecaj varijable druge razine na povezanost varijabli prve razine s kriterijem. Takav se tip interakcije u hijerarhijskim modelima naziva kros-razinska interakcija (eng. *cross-level interaction*).

Očito je da ovakvo hijerarhijsko modeliranje podataka razlaže varijancu školskog uspjeha iz Matematike na dva osnovna dijela. Može se razlikovati varijabilitet između učenika jednog razreda (osobne razlike među učenicima) i varijabilitet između razreda (razlike u uspjehu pojedinih razreda). Ako zamislimo model bez ijednog prediktora na bilo kojoj od

razina (tzv. prazni model, nul-model ili eng. *intercept-only model*) tada možemo opću jednadžbu prve razine napisati kao:

$$Y_{ij} = b_{0j} + e_{ij}$$

Dakle, rezultat nekog učenika u uspjehu iz Matematike može se dobiti kao zbroj prosjeka nekog razreda b_{0j} i odstupanja tog učenika od tog prosjeka e_{ij} .

Na drugoj razini možemo izračunati intercepte b_{0j} , odnosno aritmetičke sredine razreda jednadžbom:

$$b_{0j} = \gamma_{00} + u_{0j}$$

Ovdje određujemo aritmetičku sredinu nekog razreda kao zbroj prosjeka aritmetičkih sredina svih razreda γ_{00} i odstupanja tog razreda od prosjeka u_{0j} . Ako sve uvrstimo u početnu jednadžbu dobivamo sljedeće:

$$Y_{ij} = \gamma_{00} + u_{0j} + e_{ij}$$

Iz navedenog je vidljivo da uspjeh ih Matematike pojedinog učenika (i), koji pohađa razred (j), možemo izračunati kao zbroj prosjeka uspjeha iz Matematike svih razreda (γ_{00}), odstupanja prosjeka razreda koji učenik pohađa od općeg prosjeka uspjeha iz Matematike (u_{0j}) i odstupanja učenika od prosjeka pripadajućeg razreda (e_{ij}). Time se ukupan varijabilitet, odnosno varijanca rezultata učenika razlaže na dvije komponente: varijabilitet niže, učeničke razine analize i varijabilitet više razine, odnosno razine razreda. Unutar termina klasične analize varijance takav bi se varijabilitet mogao nazvati varijabilitetom unutar (eng. *within groups – WG*) i varijabilitetom između grupa (eng. *between groups – BG*)³.

Udio varijance više razine u ukupnoj varijanci učeničkog postignuća u obrazovnim istraživanjima od posebne je važnosti. Zato gotovo svaka hijerarhijska analiza obrazovne učinkovitosti započinje s

³ Termini varijabiliteta unutar i između grupa preuzeti iz klasične analize varijance s fiksним faktorima u ovom kontekstu nisu potpuno točni jer bi tada omjer međugrupnog i ukupnog varijabiliteta odgovarao izračunu η^2 , a ne ICC-a. Zato se ovdje termin međugrupnog varijabiliteta u stvari odnosi na ANOVA model sa slučajnom nezavisnom varijablom (eng. random model) gdje se međugrupni varijabilitet procjenjuje na populacijskoj razini (Howell, 1997).

procjenom udjela varijabiliteta rezultata učenika koji je uzrokovani varijablama više razine jer se u tom varijabilitetu traži potencijalni učinak varijabli vezanih uz osobine učitelja, razreda ili škola. Jednostavan način izračuna proporcije varijance koja se može objasniti pripadanjem grupama više razine, odnosno određenim obrazovnim strukturama u općem varijabilitetu učeničkog uspjeha, predstavlja izračun indeksa intraklasne korelacije (ICC). Indeks intaraklasne korelacije obično se označava sa grčkim slovom ρ (ρ) i izračunava po formuli:

$$\rho = \frac{\sigma_{u_0}^2}{\sigma_{u_0}^2 + \sigma_e^2}$$

Gdje je σ_e^2 varijanca odstupanja (pogrešaka) na najnižoj razini (e_{ij}), a $\sigma_{u_0}^2$ varijanca odstupanja (pogrešaka) na višoj razini (u_{0j}). Prema navedenoj formuli može se jednostavno interpretirati dobiveni koeficijent intraklasne korelacije kao udio varijabiliteta vezan uz grupnu pripadnost u ukupnom varijabilitetu rezultata⁴. Na temelju tako procijenjenog parametra mogu se postaviti očekivanja koliko je varijabiliteta teoretski moguće objasniti s prediktorskim varijablama više razine. U kontekstu istraživanja obrazovne učinkovitosti, ukoliko je ICC viših hijerarhijskih razina vrlo mali, i očekivanja o utjecaju obilježja učitelja ili škola na obrazovni uspjeh učenika će biti skromna. Ako je pak ICC velik, postoji vjerojatnost da upravo obilježja učitelja i/ili škola pridonose objašnjenju školskog uspjeha učenika.

Primjenom višerazinskih modela analize podataka u istraživanjima učinkovitosti obrazovanja može se jasno utvrditi utjecaj varijabli različitih razina analize na obrazovni uspjeh učenika. U dvorazinskoj analizi iz primjera regresijski koeficijenti prve razine govore koliko se varijabililitet učeničkog uspjeha iz Matematike može objasniti na osnovi osobnih razlika među učenicima. Regresijski koeficijenti vezani uz varijable druge razine govore o tome koliko se varijabililiteta u prosječnom uspjehu razreda u Matematici može objasniti na osnovi obilježja razreda, ali i u kojoj mjeri obilježja razreda mijenjaju povezanost osobina učenika i učeničkog

⁴ Proporcija dobivena ICC indeksom u višerazinskim modelima odnosi se na procjenu koliku bi varijancu na populacijskoj razini objašnjavala grupna pripadnost pojedinoj obrazovnoj strukturi u ukupnom varijabilitetu, a ne na proporciju varijabiliteta dobivenu na uzorku (Tabachnick i Fidell, 2007).

uspjeha. Interakcijski podaci omogućavaju razumijevanje onoga što uzrokuje (moderira) razlike u odnosima između varijabli prve razine i kriterija u različitim grupama sudionika na drugoj razini. Očito je da HLM nudi niz prednosti u odnosu na klasični regresijski nacrt koji je proveden transformacijom podataka na bilo koju od hijerarhijskih razina. Osim toga, ovako postavljen dvorazinski regresijski model može se lako proširiti uvođenjem varijabli mjerjenih na dodatnim, višim razinama. Time se u model dodaju novi izravni efekti viših razina te se multiplicira broj zanimljivih kros-razinskih interakcijskih efekata od potencijalnog istraživačkog interesa. U obrazovnim se istraživanjima vrlo često primjenjuju dvorazinski (npr. Frenzel, Pekrun i Götz, 2007) i trorazinski nacrti s razinama učenika, razreda i škola (npr. Zhao, Valcke, Desoete, Verhaeghe i Xu, 2011), a lako je zamisliti i proširenje takvih nacrta na dodatne razine, poput regija ili država.

4. Longitudinalni nacrti

Osnovno obilježje longitudinalnih nacrta je da uključuju više opažanja ili mjerena istih entiteta (npr. učenika) u više vremenskih točaka. Prilikom formiranja longitudinalnih nacrta treba obratiti pozornost na točno određenje pojma višekratnih mjerena. Recimo da želimo izmjeriti školski uspjeh učenika, operacionaliziran školskim ocjenama, u dvije vremenske točke, primjerice, na kraju šestog i osmog razreda osnovne škole. No, istraživanje prevedemo samo na kraju osmog razreda i tada učenike upitnikom pitamo koje su školske ocjene imali na kraju šestog razreda. Takav se nacrt također može nazvati longitudinalnim iako nismo imali provedena dva mjerena u dvjema vremenskim točkama, već smo podatke o prvoj točci mjerena dobili iskazom učenika. Ovakav se nacrt naziva retrospektivnim longitudinalnim nacrtom i njime se načelno, zbog same prirode prvog mjerena, dobivaju podaci nešto niže razine kvalitete od onog kojeg nazivamo prospektivnim longitudinalnim nacrtom (Gustafsson, 2010). U prospektivnom longitudinalnom nacrtu podaci su prikupljeni i u šestom i u osmom razredu, odnosno isti su učenici praćeni kroz promatrano razdoblje. Dvije su jasne prednosti prospektivnog nad retrospektivnim nacrtom. Prvo, podaci prikupljeni prospektivnim nacrtom ne temelje se na sjećanju i samoiskazu učenika koje je podložno grešći.

Drugo, tijekom vremena dolazi do određene promjene u uzorku učenika koju nije moguće lako prepoznati. Naime, neki učenici koji su zahvaćeni mjerljem u osmom razredu možda nisu dijelili istu obrazovnu okolinu kao ostali u šestom razredu, odnosno možda su se doselili naknadno u tu školu, možda su mijenjali razred, preskočili neki razred (akcelerirali) ili ponavljali neki razred u tom razdoblju. Iako ovakvi slučajevi u pravilu nisu česti, oni umanjuju kvalitetu podataka prikupljenih retrospektivnim nacrtima.

Drugi dio problema longitudinalnih nacrta vezuje se uz entitete, odnosno jedinke čija se obilježja opetovano mijere. Kao što je već napomenuto, jedno od obilježja obrazovnih istraživanja je da postoje različite razine podataka koji su na određeni način ugniježđeni jedni u druge. Tako imamo razinu učenika, učitelja, škola ili čak širih regija ili država u kojima su te škole smještene. Najčešći pristup u longitudinalnim istraživanjima jest taj da se tijekom vremena prati uspjeh učenika, kao entiteta najniže razine, te da se u istim vremenskim točkama prikupljaju podaci o obilježjima njihovih učitelja, odnosno škola. Takvi su nacrti najčešći i u literaturi se nazivaju panel-dizajnjima. No, ponekad je interes istraživača usmjerena na drugu razinu podataka. Često je to razina škola, a istraživačko pitanje koje se može postaviti jest u kojoj je mjeri obrazovno postignuće pojedinih škola stabilno i konzistentno tijekom vremena. Može se, na primjer, promatrati postignuće osmih razreda istih škola kroz nekoliko godina, ali treba biti svjestan da su podaci svake godine prikupljeni na drugim učenicima. Dakle, škole jesu iste tijekom istraživanja ali se učenici osmih razreda kroz generacije mijenjaju. Još jedan čest primjer istraživanja u kojima su jedinice na makrorazini stabilne, ali se jedinice mikrorazine mijenjaju, predstavljaju međunarodna istraživanja obrazovnog uspjeha poput PIRLS-a, PISA-e ili TIMMS-a. U takvima se međunarodnim studijama istraživanja provode svakih nekoliko godina u istim zemljama, a svaki se puta iz populacije škola ili učenika neke zemlje izvlače uzorci na kojima se primjenjuju standardizirani testovi znanja. Dakle, istraživački nacrti su longitudinalni na razini obrazovnih sistema (država), ali naravno nisu na razini učenika. Prvenstvena im je svrha utvrđivanje trenda u razini obrazovnih postignuća kod onih zemalja koje sudjeluju redovito u takvima projektima.

Longitudinalna istraživanja imaju nekoliko jasnih prednosti nad drugim istraživačkim nacrtima, ali imaju isto tako nekoliko prisutnih metodoloških problema s kojima se treba suočiti i pokušati ih prevladati. Prva i najočitija prednost longitudinalnog pristupa je mogućnost utvrđivanja stabilnosti i promjena mjerjenih pojava tijekom vremena. U području istraživanja učinkovitosti obrazovanja takvim se podacima može dati odgovor na mnoga pitanja: *Rastu li učinci učitelja i škola na učeničko postignuće tijekom vremena? Jesu li ti učinci konstantni i konzistentni? Jesu li kratkoročni ili imaju dugoročan efekt?* Ove prednosti longitudinalnog pristupa posebice dolaze do izražaja ako ih se usporedi s klasičnim kros-sekcijskim istraživanjem (korelacijsko istraživanje u jednoj točci vremena) koje ima vrlo limitiran istraživački doseg. Nadalje, longitudinalni nacrti pružaju puno više sigurnosti pri donošenju uzročno-posljedičnih zaključaka u odnosu na kros-sekcijski pristup. Naravno, ni longitudinalni pristup ne pruža potpunu sigurnost o uzročno-posljedičnim odnosima, što omogućavaju jedino eksperimentalni nacrti, no ukoliko se zadovolje neki od preduvjeta, izvjesnost zaključaka o uzrocima promjena u učeničkom postignuću znatno raste. U prvom je redu nužan jasan teorijski okvir koji podržava i omogućava razumijevanje uzročno-posljedičnih odnosa među promatranim varijablama u longitudinalnom nacrtu. Drugi element longitudinalnih nacrtova koji osigurava veću sigurnost zaključaka o uzrocima i posljedicama je sustavno uvođenje i mjerjenje identične nezavisne varijable u svakoj suksesivnoj točci mjerjenja. Nadalje, potrebno je teorijski utemeljeno i sveobuhvatno u istraživanje uključiti i sve ostale pozadinske varijable koje bi pored istraživačke varijable od interesa (nezavisne varijable) mogle utjecati na rezultat u zavisnoj varijabli (kriteriju). Kao što je već navedeno, njihov se utjecaj mora parcijalizirati, ukloniti iz varijabiliteta zavisne varijable da bi se s većom sigurnosti moglo zaključiti o utjecaju nezavisne varijable na kriterij. Milas (2009) daje sličan pregled preduvjeta kauzalnih analiza u longitudinalnim istraživačkim nacrtima. Dakle, ako se longitudinalni nacrt provede u dovoljno vremenskih točaka, unutar jasno postavljenog teorijskog okvira, ako se sustavno mijere obilježja učitelja i škola, ako se koristi pouzdan i valjan kriterij učeničkog postignuća te se sustavno kontroliraju ostale pozadinske osobine učenika koje mogu utjecati na postignuće, moguće je, s velikom

dozom sigurnosti, donijeti zaključak o obrazovnim uzrocima učeničkog uspjeha.

Od metodoloških problema s kojima se treba suočiti tijekom provedbe longitudinalnih istraživanja vjerojatno je najvažniji osipanje podataka tijekom vremena. Pod ovim se ne misli samo na osipanje učenika tijekom višekratnih ispitivanja već i osipanje drugih relevantnih sudionika prisutnih u istraživanjima učinkovitosti obrazovanja. Dakle, učenici, učitelji ili ravnatelji mogu mijenjati škole, razboljevati se u pojedinim točkama vremena ili napustiti obrazovni sustav. Time se nužno gubi velik dio podataka u jednoj ili više točaka mjerena. Na sreću, ako takva osipanja nisu jako velika i nisu uzrokovana nekim sistematskim faktorima, sofisticirani statističko-analitički programi omogućavaju istraživačima da se relativno uspješno nose s tim problemom. Drugi veliki izazov longitudinalnih istraživanja je kreiranje kriterijskih mjera (najčešće mjera znanja) koje su komparabilne, jednako pouzdane, osjetljive i valjane tijekom višekratnih mjerena. Dakle, očito je da se moraju razviti različite, a opet po svim metrijskim osobinama usporedive mjere znanja primjenjive kroz višekratna mjerena. Zato je potrebno veliku pažnju posvetiti razvoju kriterijskih mjera prije provođenja samog longitudinalnog nacrta, a promjena modernih psihometrijskih metoda poput *Teorije odgovora na cestice* (eng. *Item Response Theory – IRT*) mogu pri tom biti od velike koristi (Verhelst, 2010a; 2010b).

5. Metode analize podataka u longitudinalnim nacrtima

Suvremena istraživanja učinkovitosti obrazovanja koja počivaju na analizi longitudinalnih podataka odmiču se od klasičnih pristupa ponovljenih mjerena u analizi varijance (ANOVA) ili analizi kovarijance (ANCOVA). Razlog promjene statističke metode leži u strogosti postavljenih preduvjjeta za provedbu analize varijance ponovljenih mjerena. Naime, prvi problem je u postojanju osipanja podataka kroz opetovana mjerena koje je, kao što je ranije navedeno, sveprisutno u obrazovnim istraživanjima. Klasični ANOVA modeli tretiraju nepostojanje bilo kojeg podatka u bilo kojoj točci vremena za nekog ispitanika kao potpuni gubitak tog ispitanika u analizi (eng. *listwise deletion*). Dakle, uzorak na kojem se provodi analiza je smanjen i sveden

samo na one ispitanike koji imaju kompletne podatke u svim mjeranjima. Time se bitno smanjuje veličina uzorka, posljedično i statistička snaga istraživanja, a umanjena je i točnost procjene pojedinih mjera prikupljenih u pojedinim vremenskim točkama. Drugi problem leži u još jednom važnom preduvjetu za provedbu ANOVE ponovljenih mjeranja, a to je očekivanje da su varijance učeničkog postignuća u pojedinim mjeranjima, kao i kovarijance parova mjera učeničkog postignuća u različitim mjeranjima podjednake. Dakle, taj se preduvjet odnosi na homogenost, odnosno sličnost svih parova kovarijaničnih matrica zavisne varijable i naziva se preduvjetom zajedničke simetričnosti (eng. *compound symmetry*; npr. Howell, 2007; Hedeker i Gibbons, 2006). U obrazovnim istraživanjima on je vrlo često narušen jer nije vjerojatno da će korelacije među parovima mjeranja biti uvijek jednake. Često će mjerena provedena u bližim vremenskim točkama biti povezana negoli ona u vremenski udaljenijim. Na primjer, povezanost između ocjena iz Matematike u sedmom i osmom razredu bit će vjerojatno veća nego li između ocjena iz Matematike u trećem i osmom razredu. Zbog navedenih ograničenja klasičnih statističkih modela analize ponovljenih mjeranja, istraživači se okreću upotrebi regresijskih modela analize podataka koji počivaju na drugačijim pristupima (Gustafsson, 2010; Hedeker i Gibbons, 2006; Hox, 2010).

U ovom prikazu oslonit ćemo se na primjenu višerazinske regresijske analize u obradi longitudinalnih podataka čije smo osnove objasnili u prethodnom poglavlju. Dakle, prikazat ćemo kako primjeniti hijerarhijske regresijske modele za analizu podataka prikupljenih višekratnim mjeranjima, odnosno longitudinalnim istraživačkim nacrtima. Višerazinska regresijska analiza primjenjena na longitudinalnim podacima rješava oba ranije navedena ograničenja klasičnih statističkih pristupa. Može se uspješno nositi s nepotpunim podacima prikupljenim u pojedinim točkama mjeranja te ne zahtijeva uvjete zajedničke simetričnosti među parovima ponovljenih mjeranja.

Da bismo mogli shvatiti logiku na kojoj počiva primjena hijerarhijskih regresijskih modela u analizi longitudinalnih podataka trebalo bi na početku stvoriti sliku longitudinalnih podataka koja je malo drugačija od one intuitivne i tradicionalno prihvaćene. Primijenivši hijerarhijsku logiku na longitudinalne podatke možemo zamisliti da su

višekratne mjere učeničkog uspjeha u promatranim vremenskim točkama u stvari ugniježđene unutar učenika. U tom pristupu učenici predstavljaju višu hijerarhijsku razinu analize, dok su na najnižoj sve prikupljene mjere uspjeha u različitim vremenskim točkama. Ovakva je logika opravdana jer je jasno da su rezultati jednog učenika u nekoliko mjerjenja neosporno određeni upravo njegovim osobinama. Na primjer, obilježje učenika, poput njegova spola ili socio-ekonomskog statusa djeluje na njegov uspjeh u svim opetovanim mjerjenjima. Zato se i kod ponovljenih mjerjenja može primijeniti logika višerazinske regresijske analize sa svim njezinim obilježjima.

Ipak, prilikom definiranja takvog regresijskog modela treba voditi računa o osobinama varijabli mjerjenih na višoj razini (najčešće razini učenika). Postoje takozvane vremenski promjenjive varijable (eng. *time-varying covariate*), odnosno one čija se vrijednost mijenja od mjerjenja do mjerjenja (npr. razina motivacije ili predznanje učenika). Postoje i varijable koje mogu biti konstantne na višem hijerarhijskom nivou kroz sva mjerjenja (npr. spol učenika) i one se nazivaju vremenski nepromjenjive varijable (eng. *time-invariant covariates*). Druga stvar na koju treba obratiti pozornost je da u većini programa za obradu podataka primjena višerazinskih regresijskih modela na longitudinalnim podacima zahtijeva određenu transformaciju početne tablice unesenih podataka. Za klasična ponovljena mjerjenja koja obrađujemo ANOVA-om, za svakog ispitanika imamo jedan redak podataka, a njegove rezultate u ponovljenim mjerjenjima tretiramo kao varijable u stupcima. U zasebnim stupcima su i bilo koje druge varijable koje se odnose na obilježja učenika. Da bismo mogli primijeniti višerazinsku regresijsku analizu na takvim podacima potrebno ih je transformirati. Za svakog je ispitanika potrebno napraviti onoliko redaka koliko ima rezultata u ponovljenim mjerjenjima. Dakle, svaki redak je definiran s rednim brojem ispitanika i s rednim brojem mjerjenja. Da bi to bilo moguće, potrebno je formirati i novu varijablu T koja definira na koje se mjerjenje u svakom retku podaci odnose. Za svakog ispitanika imamo t točaka mjerjenja, odnosno t redaka. Time se broj redaka matrice proširuje na $n \times t$. Broj zavisnih varijabli svodi se na samo jednu. Ona je prikazana u jednom stupcu, a za jednog ispitanika poprima onoliko vrijednosti koliko je mjerena. Ostale varijable razine učenika ili neke više razine prikazane su u pojedinim stupcima. Vremenski nepromjenjive

varijable imaju iste vrijednosti za pojedinog učenika u svim točkama mjerena, dok vremenski promjenjive imaju varijabilne vrijednosti unutar jednog učenika kroz različite jedinice vremena. Ovakva transformacija podataka je vrlo lako izvediva u većini statističkih programskih paketa za obradu podataka (npr. SPSS).

Tako restrukturirane podatke ponovljenih mjerena možemo podvrći obradi višerazinskim regresijskim jednadžbama. Na najnižem nivou, prognoza obrazovnog postignuća učenika definirana je jednadžbom:

$$Y_{ti} = \pi_{0i} + \pi_{1i}T_{ti} + \pi_{2i}X_{ti} + \dots + \pi_{ki}X_{ti} + e_{ti}$$

Vidljive su dvije razlike između ove jednadžbe i klasične regresijske jednadžbe. Prva je postojanje grčkog slova π , umjesto standardnog b ili β . To je standardna nomenklatura regresijski koeficijenta prvog nivoa u longitudinalnim podacima. Prednost takve nomenklature je u mogućnosti korištenja standardnog β (ili b) koeficijenta na drugom nivou analize. Drugi *novi* element je postojanje indeksa t koji se odnosi na pojedine vremenske točke mjerena (umjesto j za pripadanje ispitanika nekoj grupi u klasičnom HLM-u). Nadalje, tu je i postojanje varijable T koja predstavlja indikator vremenske točke mjerena. Obično je varijabla T kodirana brojčanim vrijednostima od 0 do t (0, 1, 2, 3, ..., t) za pojedine vremenske točke mjerena. Takvim kodiranjem se početak mjerena postavlja kao točka u kojoj se intercept (π_{0i}), u takozvanom praznom ili nul-modelu može interpretirati kao prosječna vrijednost zavisne varijable na početku mjerena (npr. prosjek učeničkog školskog postignuća pri početnom mjerenu).

Ako se vratimo na jednadžbu, Y_{ti} predstavlja rezultat ispitanika (i) u vremenskoj točci (t); T_{ti} je varijabla vremena koja predstavlja identifikator za svaku vremensku točku (t); X_{ti} je vremenski promjenjiva varijabla na razini učenika (i) mjerena opetovano u svakoj pojedinoj vremenskoj točci (t); dok je e_{ti} pogreška prognoze za učenika (i) u vremenskoj točci (t). Treba napomenuti da varijabla X u ovoj jednadžbi predstavlja vremenski promjenjivu varijablu na razini učenika, pa je zato ubrojena kao prediktor prve razine analize. Regresijski koeficijenti prve razine π , ako nemamo dodatne fiksne varijable na razini učenika imaju

jasno interpretacijsko značenje. Koeficijent π_{1i} daje informaciju koliki se varijabilitet u zavisnoj varijabli može pripisati proteku vremena (može se interpretirati i kao utjecaj tretmana, trend i sl.), dok koeficijent π_{2i} govori o objašnjrenom varijabilitetu u kriteriju na osnovi vremenski promjenjivog prediktorskog obilježja ispitanika.

Ako koristimo primjer analogan onome ih HLM-a možemo zamisliti da mjerimo učeničko postignuće iz Matematike svake godine tijekom osnovne škole te da na nivou učenika imamo varijablu spola i varijablu motivacije za učenje matematike (svake godine primjenjujemo motivacijski upitnik). Tada imamo osam vremenskih točaka mjerena, jednu vremenski nepromjenjivu i jednu vremenski promjenjivu prediktorsku varijablu na razini učenika. Vremenski promjenjiva nezavisna varijabla na razini učenika (motivacija) uključena je u jednadžbu na prvoj razini, dok je druga, kao invarijantna osobina učenika, uvedena na drugoj razini hijerarhijske analize. Jednadžbe druge razine možemo simbolički raspisati na sljedeći način:

Za intercept:

$$\pi_{0i} = \beta_{00} + \beta_{01}Z_i + u_{0i}$$

Za regresijske koeficijente:

$$\pi_{1i} = \beta_{10} + \beta_{11}Z_i + u_{1i}$$

$$\pi_{2i} = \beta_{20} + \beta_{21}Z_i + u_{2i}$$

U ovim jednadžbama varijabla Z predstavlja vremenski nepromjenjivu varijablu na razini učenika. Pripadajući regresijski koeficijent β_{01} daje informaciju u kojoj mjeri ta varijabla općenito objašnjava razlike među učenicima, odnosno pruža informaciju o glavnom efektu te varijable u terminima ANOVA-e. Koeficijent β_{11} daje informaciju u kojoj je mjeri promjena rezultata u kriteriju tijekom vremena ovisna o varijabli Z , dok koeficijent β_{12} daje informaciju u kojoj se mjeri, utjecaj vremenski promjenjive varijable X na kriterij, mijenja pod utjecajem vremenski nepromjenjive varijable Z . Interpretacija regresijskih koeficijenata kojima se prognoziraju varijacije u nagibima pravaca regresije odgovara interpretaciji interakcijskih učinaka u ANOVA-i.

Uvođenjem jednadžbi s druge razine u osnovnu jednadžbu prve razine dobivamo:

$$Y_{it} = \beta_{00} + \beta_{10}T_{ti} + \beta_{20}X_{ti} + \beta_{01}Z_i + \beta_{11}T_{ti}Z_i + \beta_{21}X_{ti}Z_i + u_{1i}T_{ti} + u_{2i}X_{ti} + u_{0i} + e_{ti}$$

Isto zapisano sadržajem varijabli iz primjera izgleda ovako:

$$\text{mat}_{it} = \beta_{00} + \beta_{10}\text{vrijeme}_{ti} + \beta_{20}\text{motiv}_{ti} + \beta_{01}\text{spol}_i + \beta_{11}\text{vrijeme}_{ti} \times \text{spol}_i + \beta_{21}\text{motiv}_{ti} \times \text{spol}_i + u_{1i}\text{vrijeme}_{ti} + u_{2i}\text{motiv}_{ti} + u_{0i} + e_{ti}$$

Dakle, β_{10} govori o promjenama u znanju matematike koje se mogu pripisati proteku vremena. Koeficijent β_{20} govori o značajnosti utjecaja motivacije učenika na znanje iz matematike, dok koeficijent β_{01} nosi u sebi spolne razlike u postignuću iz matematike. Ova tri koeficijenta imaju značenje glavnih efekata u klasičnom ANOVA modelu. Koeficijenti β_{11} i β_{21} govore o interakcijskim učincima. U prvom slučaju o tome u kojoj su mjeri promjene u znanju matematike tijekom vremena različite za dječake i djevojčice, a u drugom mijenja li se opći utjecaj motivacije na znanje matematike ovisno o spolu učenika. Osim regresijskih koeficijenata uz prognozu se, naravno, vezuju i određene pogreške $[u_{1i}T_{ti} + u_{2i}X_{ti} + u_{0i} + e_{ti}]$ vezane uz slučajni, varijabilni (eng. *random*) dio modela.

U longitudinalnim modelima, kao i kod HLM-a, poželjno je na početku izračunati koeficijent intraklasne korelacije (ICC). Njegova vrijednost pruža mogućnost interpretacije odnosa varijabiliteta vezanog uz osobne razlike među učenicima (varijabilitet između ispitanika) i varijabiliteta vezanog uz promjene unutar samih učenika tijekom vremena (varijabilitet unutar ispitanika). Naravno, varijabilitet unutar ispitanika je zanimljiviji istraživačima u području obrazovanja, jer su oni zainteresirani za obrazovne faktore koji potencijalno leže u promjenama učeničkog uspjeha tijekom vremena.

U izračun koeficijenta intraklasne korelacije treba krenuti od praznog modela (nul-modela), odnosno modela bez ijednog prediktora. U jednadžbi na prvom nivou analize preostaje samo $Y_{it} = \pi_{0i} + e_{ti}$. Ovdje varijanca σ_e^2 govori o odstupanjima pojedinca od vlastitog prosječnog rezultata u svim mjeranjima (π_{0i}). Taj bi varijabilitet u analizi varijance ponovljenih mjeranja odgovarao varijabilitetu unutar ispitanika. Ako predviđamo intercept π_{0i} s prvog nivoa, praznim modelom s drugog nivoa koristimo jednadžbu $\pi_{0i} = \beta_{00} + u_{0i}$. Tu σ_{u0}^2 , govori o varijabilitetu

prosječnog rezultata pojedinaca u svim mjerljima oko aritmetičke sredine svih učenika kroz sva mjerljena (β_{00}), odnosno govori o varijabilitetu između ispitanika. Dakle, ukupni rezultat nekog učenika (i) u mjerljenu (t) može se izraziti formulom $Y_{ti} = \beta_{00} + u_{0i} + e_{ti}$, odnosno izračunati kao zbroj: aritmetičke sredine svih učenika u svim mjerljima (β_{00}); odstupanja prosječnog rezultata učenika (i) u svim mjerljima od te aritmetičke sredine; i odstupanja rezultata tog učenika u mjerljenu (t) od njegova prosječnog rezultata. Time je jasno da se ukupni varijabilitet u stvari razlaže na varijabilitet unutar i između ispitanika što je i ranije poznato iz analize varijance ponovljenih mjerljena.

Koeficijent intraklasne korelacije izračunat prema formuli $\rho = \sigma_{u0}^2 / (\sigma_{u0}^2 + \sigma_e^2)$ govori o udjelu varijabiliteta između ispitanika u ukupnom varijabilitetu. Kako interes istraživača uglavnom nije usmjeren na taj dio varijance zavisne varijable korisno je izračunati $1 - \rho$ čime se dobiva udio varijance unutar ispitanika u cijelokupnom varijabilitetu. Ako je u obrazovnim istraživanjima taj udio varijabiliteta relativno velik tada se najčešće može pretpostaviti da se pomak u učeničkom postignuću zapažen tijekom vremena potencijalno može objasniti nekim faktorima vezanim uz učitelje, nastavni proces ili obilježja škole.

U danom primjeru korištene su samo dvije varijable mjerene na razini učenika (motivacija i spol), ali je vrlo lako proširiti ovaj model uvodeći varijable dodatnih hijerarhijskih razina, poput varijabli razine razreda, učitelja ili škola. Potrebno je samo proširiti navedenu regresijsku jednadžbu onako kako je to opisano u ranijim poglavljima, odnosno razviti višerazinski model.

Postoje brojni statistički programi kojima je u potpunosti ili u velikoj mjeri moguće provesti ovakve analize podataka računalno. Neki od njih su opći programi za analizu podataka, široko rasprostranjeni među istraživačima u području društvenih znanosti poput SPSS-a ili STATA-e. Oni su relativno jednostavni za korištenje i svojim sučeljem prilagođeni korisnicima nevještima u programiranju ili matematičkim formulama. Ipak, ti programi imaju određena ograničenja i nedostatke kod složenijih hijerarhijskih analiza. Danas su dostupni specijalizirani statistički programi, razvijeni i dizajnirani upravo za provođenje višerazinskih analiza podataka (np. program HLM), dok neki drugi napredni statistički paketi kao što su Mplus, MLwiN ili R s lakoćom obavljaju ovakve analize.

Potonji sofisticirani programi zahtijevaju od korisnika poznavanje specifične sintakse (programskog jezika) za pozivanje određenih analitičkih procedura pa i dodatnu edukaciju za njihovo uspješno korištenje.

Na kraju, važno je napomenuti da su istraživanja učinkovitosti obrazovanja, zbog hijerarhijske i longitudinalne prirode prikupljenih podataka, tijekom zadnjih desetljeća išla u korak s uvođenjem naprednih statističkih metoda. Poticala su njihov razvoj, promicala njihovu upotrebu i informirala znanstvenu zajednicu o njihovoj važnosti. Današnja obrazovna istraživanja izrazito su temeljena na upotrebi najsuvremenijih statističkih postupaka, a daljini napredak i istraživački pomak u ovom području je nezamisliv bez upotrebe, barem osnovnih, a u ovom poglavlju ukratko opisanih, statističkih procedura.

Literatura

- Bryk, A. S., & Raudenbush, S. W. (1992). *Advanced qualitative techniques in the social sciences, 1. Hierarchical linear models: Applications and data analysis methods*. Thousand Oaks: Sage Publications, Inc.
- Creemers, B. P. M., & Kyriakides, L. (2008). *The dynamics of educational effectiveness: A contribution to policy, practice and theory in contemporary schools*. London: Routledge
- de Leeuw, J., & Kreft, I. (1986). Random coefficient models for multilevel analysis. *Journal of Educational Statistics*, 11(1), 57-85. DOI:10.2307/1164848
- Frenzel, A. C., Pekrun, R., & Götz, T. (2007). Perceived learning environment and students emotional experiences: A multilevel analysis of mathematics classrooms. *Learning and Instruction*, 17(5), 478–493. DOI:10.1016/j.learninstruc.2007.09.001
- Goldstein, H. (2003). *Multilevel Statistical Models, 3rd Edition*. London: Edward Arnold.
- Gustafsson, J. E. (2010). Longitudinal study. U Creemers, B.P.M., L. Kyriakides & P. Sammons (Ur.), *Methodological Advances in Educational Effectiveness Research* (pp. 77–101). London and New York: Taylor & Francis.
- Hedeker, D., & Gibbons, R. D. (2006). *Wiley Series in Probability and Statistics. Longitudinal data analysis*. Hoboken: Wiley-Interscience.
- Howell, D. C. (1997). *Statistical methods for Psychology (Fourth edition)*. Belmont: Duxbury Press.
- Hox, J. J. (2010). *Quantitative methodology series. Multilevel analysis: Techniques and applications (2nd ed.)*. New York: Routledge/Taylor & Francis Group.
- Luyten, J. W., & Sammons, P. (2010). Multilevel Modelling. In B. P. M. Creemers, L. Kyriakides, & P. Sammons (Eds.), *Methodological Advances in Educational Effectiveness Research* (246-276). London/New York: Routledge.

- Milas, G. (2009). *Istraživačke metode u psihologiji i drugim društvenim znanostima*. Jastrebarsko: Naklada Slap.
- Osborne, J. W. (2000). Advantages of hierarchical linear modeling. *Practical Assessment, Research, and Evaluation*, 7(1), 1-3. <http://PAREonline.net/getvn.asp?v=7&n=1>.
- Raudenbush, S. W., & Bryk, A. S. (2002). *Hierarchical Linear Models. Applications and Data Analysis Methods* (2nd ed.). Thousand Oaks: Sage Publications.
- Snijders, T. A. B. & Bosker, R. J. (1999). *Multilevel Analysis: An Introduction to Basic and Advanced Multilevel Modeling*. London: Sage.
- Tabachnick, B. G., & Fidell, L. S. (2007). *Using Multivariate Statistics* (5th ed.). New York: Allyn and Bacon.
- Verhelst, N. (2010a). Using Item Response Theory to measure outcomes and factors: an overview of Item Response Theory models. U Creemers, B.P.M., L. Kyriakides & P. Sammons (Ur.), *Methodological Advances in Educational Effectiveness Research* (pp. 153–182). London and New York: Taylor & Francis.
- Verhelst, N. (2010b). IRT models: parameter estimation, statistical testing and application in EER. U Creemers, B.P.M., L. Kyriakides & P. Sammons (Ur.), *Methodological Advances in Educational Effectiveness Research* (pp. 183–218). London and New York: Taylor & Francis.
- Zhao, N.N., Valcke, M., Desoete, A., Verhaeghe J., & Xu, K. (2011). Multilevel analysis on predicting mathematics performance in Chinese primary schools: implications for practice. *Asia-Pacific Education Researcher*, 20 (3), 503-520.

Contemporary research designs and data analysis techniques in educational research

Abstract

Contemporary educational research is based on the use of appropriate research designs, comprehensive data assessments and contemporary models of the data analysis. Methodological breakthroughs in this area, over the last few decades, are significant, and researchers have recognized the importance of longitudinal research designs. Moreover, the understanding of the hierarchical organization of collected data and the application of corresponding statistical analyses becomes a methodological imperative. This paper provides a methodological overview of hierarchical and longitudinal data organization and the theoretical framework of their statistical analysis. Most common errors and difficulties in the application of those methods are highlighted, and the approaches on how to overcome it are suggested. Through simple and everyday examples, these approaches are presented to the readers, and educational researchers are directed on how to adequately use it.

Keywords: *hierarchical models; longitudinal designs; data analysis; educational research; statistics*