

*Tihana Škrinjarić**

Marno Verbeek

A GUIDE TO MODERN ECONOMETRICS,

5th edition, Wiley, New Jersey, 2017., str. 520

Poznavanje kvantitativnih metoda i modela danas je jedan od važnih dijelova mikro i makroekonomskih analiza, kao i poslovnih analiza. S obzirom da danas postoji mnoštvo ekonometrijskih udžbenika koji obrađuju osnovne modele i metode potrebne za uspješne empirijske analize, potrebno je (pogotovo za početnike) pronaći one koji će čitatelju omogućiti brzo i kvalitetno savladavanje gradiva, uz balansiran omjer teorije i primjera. Knjiga „*A guide to modern econometrics*“ je danas već popularna s obzirom da je prvo izdanje izašlo 2000. godine, a ovo koje se obrađuje u ovome prikazu je već peto. I ta činjenica govori o korisnosti sadržaja ove knjige, kao i adekvatnog pristupa autora za objašnjenje odabranih ekonometrijskih modela i metoda čitateljima. Sam autor na početku navodi kako je ova knjiga rezultat predavanja na sveučilištu u Tilburgu, pri čemu su nova izdanja nastajala s obzirom na brze promjene u razvoju ekonometrije i širenja njenih primjena. Knjiga se sastoji od 10 poglavlja i 2 poglavlja koja su dodatak, gdje se osnovni pojmovi matematike i statistike ponavljaju s obzirom da se koriste u prvih 10. Prema težini, ovi materijali bi se mogli svrstati početničku do srednju razinu. Novina u petome izdanju u odnosu na prethodna nalazi se u ažuriranju nekih pojmova i koncepata, uključuje nove materijale o kauzalnoj inferenciji, p -vrijednostima i ograničenjima njihove upotrebe, procjene modela s instrumentalnim varijablama i novijim primjerima koji su opsežniji nego prije. Autor je svjestan da odabirom nekoliko generalnih važnih tema u ekonometriji nije mogao svaku obraditi detaljno. Stoga na potrebnim mjestima čitateljima navodi obvezne reference za produbljivanje znanja potrebnog da bi se vlastite empirijske analize mogle kvalitetno provesti. Na kraju

* Dr. sc. T. Škrinjarić, postdoktorandica, Ekonomski fakultet, Sveučilište u Zagrebu (E-mail: tskrinjaric@efzg.hr).

svakog poglavlja dana su pitanja za ponavljanje, uz primjere modela za interpretaciju i provedbu vlastitih procjena nad podacima koji se nalaze na web stranici izdavatelja (potrebno je registrirati se *online* kako bi imali pristup skupu podataka u primjerima i zadacima za rješavanje).

Autor u prvome poglavlju iznosi neka zanimljiva pitanja koja ekonomisti u svojim analizama mogu postaviti, te daje kratak pregled onoga što slijedi u ostatku knjige. Stoga je u ovoj knjizi efektivnih 9 poglavlja. Drugo, treće i četvrto poglavlje povezani su s obzirom da predstavljaju temelj za početak učenja ekonometrije; a redom su naziva *Uvod u linearnu regresiju*, *Interpretacija i usporedba regresijskih modela* te *Heteroskedastičnost i autokorelacija*. Dakle, ova su poglavlja osnovica za bilo kakvu daljnju nadogradnju učenja ove materije. Stoga čitatelji već upoznati s navedenim pojmovima mogu krenuti na učenja daljnjih poglavlja. Međutim, spomenuta poglavlja ipak uključuju i određene napomene autora proizašle iz dugogodišnjeg iskustva. U drugome poglavlju se prikazuju i analitički i matrični zapisi regresijskog modela, pri čemu se daju detaljna pojašnjenja te kao i ostatak knjige, ne nalazi se mnogo matematičkog jezika i formalnih zapisa, s obzirom da je knjiga namijenjena najprije publici iz područja ekonomije. Još se u drugome poglavlju obrađuju standardni pojmovi poput Gauss-Markovljevih pretpostavki modela, (i asimptotska) svojstva OLS procjenitelja, interpretaciji procijenjenog modela, kvalitete modela (engl. *goodnes of fit*), *t*-testa, itd. uz primjer koji se prožima kroz cijelo poglavlje. Kako čitatelji često imaju problema s greškama tipa *I* i *II*, autor poseban dio ovog poglavlja posvećuje tome da razjasni te greške kao i što se često u praksi pogrešno interpretira *p*-vrijednost kao vjerojatnost da je nulta hipoteza testa istinita, a u biti se radi o vjerojatnosti dobivanja određenih rezultata ako je nulta hipoteza istinita (Verbeek, 2017:13; Wasserstein i Lazar, 2016; Cumming, 2012). Lako je čitati i pratiti što autor želi pojasniti i simbolički, i riječima, kao i u ostatku knjige, što je posljedica dugogodišnjeg iskustva. Jedno potpoglavlje je posebno posvećeno svim interpretacijama na primjeni CAPM (engl. *Capital Asset Pricing Model*) modela iz financija, kako bi se sintetizirali svi pojmovi koji su do tog trenutka obrađeni. Na taj način se uočava da autor nastoji pronaći primjene koje su bliske čitateljima u praksi i kako bi lakše savladali materiju. Posebno potpoglavlje posvećeno je problemima s nedostajućim podacima i netipičnim vrijednostima; gdje autor daje svoje preporuke, ali i upućuje na literaturu koja se time detaljnije bavi. To se može uočiti kroz cijelu knjigu, stoga zainteresirani čitatelji mogu dobiti više uvida u određene teme koje ih dodatno zanimaju. Na kraju poglavlja dani su zadaci za vježbu, čime je pokriveno čitavo poglavlje dosta detaljno. Treće poglavlje se detaljnije usmjerava na interpretacije procijenjenih rezultata, s obzirom na različite specifikacije modela. Poseban dio poglavlja posvećuje se odabiru varijabli za ulazak u model te se dosta literature navodi za dodatno istra-

živanje, što govori o problemu s kojima se u empirijskim istraživanjima susrećemo. Tu se nadodaju i pojašnjavaju mjere i kriteriji s kojima se mogu uspoređivati modeli kako bi se lakše odabrao adekvatan broj varijabli u modelu, a dodatno se opisuje kako usporediti dva modela koji se ne preklapaju (engl. *non nested models*). Tu se na gotovo 20 stranica tri primjera detaljno obrađuju u sklopu pojmova obrađenih prethodno. Četvrto poglavlje bavi se problemima heteroskedastičnosti i autokorelacije reziduala modela, s obzirom da su dvije pretpostavke koje se odnose na nepromjenjivost varijance i nekoreliranost reziduala u regresijskim modelima najčešće narušene u praksi. Najprije se analiziraju posljedice postojanja tih problema, a potom kako ih riješiti. Primjerice, obrađuje se FGLS procjenitelj (engl. *feasible generalized least squares*), WLS (engl. *weighted least squares*) te HCSE standardne pogreške (engl. *heteroskedasticity consistent standard errors*) i slično (HAC za oba problema, engl. *heteroskedasticity and autocorrelation consistent*). Detaljno se obrađuju različiti testovi heteroskedastičnosti s obzirom na problem malih uzoraka, potom kada su nepoznate varijance procjenitelja, multiplikativna heteroskedastičnost. Slično se analizira i autokorelacija reziduala: posljedice, brojni testovi (posebno asimptotski). Za oba problema posebno se analiziraju i interpretiraju rezultati. Uvijek se radi o ekonomskim primjenama, pa tako i sada, makro i poslovne analize. Doprinos ove knjige u odnosu na postojeću literaturu jest što ovo poglavlje doista detaljno analizira dva spomenuta problema s mnoštvom testova i mogućnosti kako ukloniti ili ublažiti ove probleme alternativnim načinima procjene regresijskog modela.

U poseban, drugi dio knjige mogu se svrstati poglavlja pet, šest i sedam, s obzirom da se prirodno nadograđuju na prvi dio knjige. Peto poglavlje, naziva *Endogeni regresori, instrumentalne varijable i GMM* (engl. *Generalized method of moments*) najprije se bavi slučajevima kada se OLS procjenitelj ne može primjenjivati. Izvode se svojstva procjenitelja kada postanu nekonzistentni ili pristrani u slučaju kada slučajna varijabla postaje endogena u modelu, ili ako se pak izostave bitni regresori. Također se napominje i problem obrnute kauzalnosti u modelima s jednom jednadžbom te se ovdje kratko spominje mogućnost primjene modela simultanih jednadžbi. Čest problem koji se može javiti u praksi jest da nezavisne varijable nisu egzogene, stoga se razmatraju modeli s uključenim instrumentalnim varijablama. Kako se radi o pojmovima koji su nešto teži u odnosu na prvi dio knjige, autor uz formalne zapise opširno opisuje nad stvarnim primjerima što znači da je neki regresor endogen u modelu kako bi čitatelj lakše razumio. Kao primjer u konkretnom slučaju uzima se učinak broja godina školovanja na plaću zaposlenika, te ne uključivanja drugih varijabli, poput inteligencije ili sposobnosti na poslu. Paralelno se uvode novi pojmovi na teoretskoj razini i kroz primjer. Tako je uvođenje instrumentalne varijable u spomenuti model najprije objašnjeno s mate-

matičkog stajališta, a potom i kroz primjer (uzimajući kao primjer varijablu cijene školovanja za instrumentalnu). Autor se ovdje poziva i na probleme u empirijskim istraživanjima jer uočava da se često kao instrumentalne varijable uzimaju proizvoljne varijable bez razumnog opravdanja (vidjeti i Larcker i Rusticus, 2010). U primjeru koji obuhvaća sve obrađivano do tada, može se uočiti da je autor odabrao takav model i varijable koji je dosta u praksi razmatran za komentiranje instrumentalnih varijabli za modeliranje individualnih plaća. To je vidljivo iz brojne literature koju ovdje spominje i kako su autori pristupili rješavanju određenog problema. Ovo je također doprinos ove knjige, što se često ne nalazi takav pristup gdje se rješavanje nekog problema nastoji prikazati s više kutova gledišta. Posebno potpoglavlje posvećeno je GIVE procjenitelju (engl. *generalized instrumental variables estimator*, 2SLS procjenitelj – *two stage least squares*). I ovdje se može uočiti taj pristup. Prethodno spomenuti pristupi su posebni slučajevi generalizirane metode momenata, stoga se posljednji dio ovog potpoglavlja posvećuje GMM metodi procjene parametara. Radi se o sažetom prikazu, no s dovoljno potrebnih detalja kako bi čitatelj mogao razumjeti važnost ove metode, i konačno je dan primjer ICAPM modela kao jedne primjene GMM metode procjene. Jedna od prednosti ove metode jest što se rade pretpostavke samo na neke momente distribucija parametara, dok se jače pretpostavke obrađuju u idućem, šestom poglavlju. U ovome poglavlju, *Metoda najveće vjerodostojnosti i testovi specifikacije*, obrađuje se metoda koja vrši pretpostavku o čitavoj distribuciji. Međutim, time procjenitelj postaje asimptotski efikasan. Najprije se prikazuje zajednička funkcija gustoće uz pretpostavku normalne distribucije, potom se razmatraju svojstva procjenitelja, te se rješavaju primjeri i uspoređuje ova metoda s metodom najmanjih kvadrata. Kao tri važna testa temeljena na rezultatima procjene pomoću ML metode obrađuju se Waldow test, LR (engl. *likelihood ratio*) i LM (engl. *Lagrange multiplier*) test. Pomoću ovih testova može se analizirati niz istraživačkih pitanja, stoga se za svaki pokazuje postupak provođenja. Ako se pak izvrši generalizacija na način da se uvjeti na momente u GMM metodi promatraju kao nužni uvjeti u ML metodi, dolazi se do kvazi ML metode, koja se potom obrađuje u posljednjem dijelu ovog poglavlja. Procjenitelji dobiveni ovom metodom su konzistentni i u slučaju da slučajna varijabla nije normalno distribuirana, stoga autor predočava prednosti i mogućnosti korištenja ove metode. Sedmo poglavlje (*Models with Limited Dependent Variables*) posvećeno je modelima i metodama koje se bave zavisnim varijablama s posebnim karakteristikama, poput binarnih varijabli i tzv. *count data* (podaci poprimaju negativne cjelobrojne vrijednosti). Ovo je ujedno i najveće poglavlje, s obzirom na raspon tema i mogućnosti istraživanja, a često se i u literaturi ne nalazi dovoljno posvećenosti ovakvim modelima i metodama. Stoga autor više pažnje posvećuje određenim pojmovima, kako bi čitatelji mogli dobiti potpuniji uvid u ovo područje jer su mikroekonomske primjene temeljem anketnih upitnika u ovome području

brojne. Zato je potrebno kvalitetno odraditi empirijsku analizu nad takvim podacima. Poglavlje započinje s primjerom zašto ne koristiti obični regresijski model ako raspoložemo s vrijednostima zavisne varijable koje su jednake 0 ili 1 (problem heteroskedastičnosti). Motivacija je dobro prikazana, kako bi čitatelj shvatio zašto su neki model ili metoda dobri za određen skup podataka ili ne. Na taj način se osigurava prirodni tijek učenja. Naravno, osnovna dva modela koja se najprije obrađuju su *logit* i *probit* modeli. Osim formalnog zapisa i karakteristika, prikazuje se metoda procjene, što je naravno, ML metoda iz prethodnog poglavlja. Stoga se ovo poglavlje prirodno nastavlja na šesto. Korak po korak je prikazan postupak nalaženja rješenja. Također, kako se kvaliteta modela ocjenjuje drugim mjerama u odnosu na koeficijent determinacije kod obične regresije, autor navodi i dodatnu literaturu za raspravu o mjerama kvalitete, s obzirom da kod modela s binarnom zavisnom varijablom ne postoji samo jedna jedina mjera. Autor navodi početne mjere koje se često uzimaju u ovakvim analizama, pseudo R^2 te McFaddenov R^2 . Dodatno se još 3 mjere obrađuju kao polazna točka za čitatelje. Ekonomski primjer se obrađuje neposredno nakon ovog uvoda u metodologiju, gdje se opsežno interpretiraju rezultati 3 modela i njihova kvaliteta te su obrađeni testovi specifikacije u ovakvim modelima. S obzirom da u provođenju ankete u praksi odgovori koje daju ispitanici mogu poprimati nekoliko vrijednosti (ne samo 0 i 1 kao kod *logit* i *probit* modela), posebno potpoglavlje posvećeno je takvim analizama (modeli su nazvani *multiresponse models*): modeli rangiranih odabira (engl. *ordered response models*) uz čak dva obrađena primjera, multinomialni modeli (engl. *multinomial*) te *count data* modeli. Autor očito zna što čitatelje inače zbunjuje kod ovakvih modela pa zato na početku svakog potpoglavlja dodatno pojašnjava o čemu se radi te navede kratke primjere podataka koji su prikladni za pojedini model. Tobit model se obrađuje u posebnom potpoglavlju, s obzirom na brojne mogućnosti njegove primjene u mikro i makro analizama (prikazane su karakteristike modela, metoda procjene, interpretacije rezultata, kao i primjer), i dodatno se obrađuju i ekstenzije tog modela (poput Tobit II i III modela) i postojeći primjer se nadograđuje kako bi se lakše usporedili rezultati svakoga. To predstavlja dobar pristup predočavanja određene materije jer se paralelno mogu usporediti prednosti i nedostaci nekog originalnog modela s njegovim proširenjima. Posljednji dio sedmog poglavlja daje uvod u procjenu učinaka tretmana (engl. *treatment effect*), s obzirom da se sve više u praksi razmatraju učinci i scenariji što ako se neki događaj nije dogodio, ili obrnuto, da se jest, koliko bi tada iznosila vrijednost neke varijable. Kako je ovakva metodologija sve popularnija za ispitivanje „što ako“ scenarija i učinaka ekonomskih politika, u ovoj knjizi su dane osnovne polazne ideje.

Treći dio knjige posvećen je vremenskim serijama. Tako se osmo poglavlje posvećuje univarijantnim vremenskim serijama (i tog je naziva), a deveto multiva-

rijatnim (istog naziva). Univarijantni modeli najviše su posvećeni prognoziranju, s obzirom da se najčešće u praksi i koriste u takve svrhe. Kako se ovdje radi o ARMA (engl. *AutoRegressive Moving Average*) modelima u većini slučajeva, početak poglavlja posvećen je pojmovima stacionarnosti, autokorelacijske funkcije uz grafičke primjere kako bi čitatelj lakše shvatio pojmove. Ovo poglavlje je pisano izuzetno tečno, stoga se oni čitatelji kojima je potrebno ovakvo modeliranje u praksi upućuju na ovo poglavlje, posebice ako se prvi put susreću s ARMA metodologijom. Prirodno se poglavlje nastavlja s jediničnim korijenima i testiranjem istih. Dva primjera koja se analiziraju su vezana uz dionice i prinose, kao i PPP (omjer kupovne moći). Dodatno je korisno što se interpretacije rezultata ne iznose samo s kvantitativnog stajališta, već i ekonomskog. Time se daje na značaju materije. Odabir metode procjene ARMA modela ovisi o AR i MA komponentama, stoga se samo kratko prikazuju OLS i ML metoda procjene koje su već prethodno detaljno obrađene. Naravno, prikazuju se i mjere kako odabrati adekvatan model, ponovno se obrađuje detaljan primjer, ovaj puta o perzistentnosti inflacije te je poseban dio poglavlja posvećen prognoziranju i mjerenju točnosti prognoza. Kako su GARCH (engl. *Generalized AutoRegressive Conditional Heteroskedasticity*) modeli u suštini ARMA modeli, u nastavku poglavlja se obrađuje i ova skupina modela. Uvod u GARCH modele je relativno jednostavan i elegantan, stoga se također preporuča za one koji prvi puta ulaze u spomenutu materiju. Konačno, poglavlje završava s primjerom GARCH modela nad prinosom tečaja. Međutim, dan je samo kratak uvod u ovu skupinu modela, stoga se čitateljima preporuča pogledati dalje literaturu koju autor koristi u ovome dijelu knjige. Međutim, kako ova knjiga pokriva širok raspon mogućih primjena, nije bilo moguće neke teme opsežno razmatrati s obzirom da fokus knjige nije na financijsku ekonometriju. Iduće poglavlje, deveto, posvećeno je multivarijantnim modelima, s obzirom na njihov značaj u današnjim analizama. Prije samog prelaska na isključivo multivarijantne modele obrađuju se ARDL (engl. *Autoregressive distributed lags*) modeli, koji se često pokazuju korisnima za prognoziranje. Kako ekonomske varijable ne ovise isključivo o svojim prethodnim vrijednostima, već i o drugim varijablama, ovi modeli obogaćuju strukturu ARMA modela, a dodatno se u određenim modelima koeficijenti interpretiraju kao multiplikatori (važan pojam u makroekonomiji). Nakon toga se čitatelja upozorava na problem prividne regresije pa se prelazi najprije na kointegraciju. Za lakše razumijevanje, obrađuje se najprije kointegracija između dvije varijable, na uobičajen način koji je prisutan u mnogo udžbenika, ali se ovdje obrađuje i CRDW način testiranja (engl. *cointegration regression Durbin Watson test*) kao i pristup uz procjenu superkonzistentnih parametara kointegracijske relacije. Dakle, za mnoge, nekima već poznate pojmove, obrađuju se još poneke dodatne teme kojima se postojeće znanje može upotpuniti i time unaprijediti kvaliteta empirijskog istraživanja. Grangerov teorem reprezentacije je potom predložen i obra-

đen kao nastavak na testiranje kointegracije i popraćen je ekonomskim primjerom, paritetom kupovne moći (PPP). VAR (engl. *Vector AutoRegression*) modeli su prirodan nastavak na univarijatne AR modele. U ovom dijelu devetog poglavlja dan je sažet uvod u VAR modele, no može se primijetiti kako je doista dan samo uvod. S obzirom da se knjiga usmjerava na nekoliko područja moderne ekonometrije, ne čudi što svako poglavlje nije detaljno obrađeno, već se zainteresiranog čitatelja upućuje na dodatnu literaturu posvećenu samo određenoj temi. Tako se ovdje spominje za potpuniju analizu VAR modela na Hamilton (1994), a na samom kraju cijelog poglavlja naravno, Tsay (2014) i Lütkepohl (2005). Često se u literaturi nalazi dosta kompliciran prikaz VEC (engl. *Vector Error Correction*) modela, a ovdje je taj prikaz veoma jednostavan, povezan uz VAR modele i da čitatelj lakše shvati kasnije testiranje kointegracije za više od 2 varijable odjednom u modelu (radi se o najčešćem pristupu: Johanesov test kointegracije). Nekoliko makroekonomskih primjena je interpretirano, uz prikaz standardnih testova, ali i dodatka LR testova *a priori* testiranja broja kointegracijskih relacija.

Posljednji dio knjige odnosi se na deseto poglavlje: *Modeli temeljeni na panel podacima*. Autor odmah uvodno navodi relevantnu literaturu na koju se čitatelj treba dalje osloniti nakon što savlada ovo poglavlje. Najprije se obrađuju model s fiksnim i slučajnim efektima, s odgovarajućim pretpostavkama i metodama procjene (npr. LSDV metoda za model s fiksnim efektima, engl. *least squared dummy variable*, ili FDE procjenitelj, engl. *first difference estimator*). Kratko se obrađuje i DiD procjenitelj (engl. *difference in differences*), s obzirom na već spomenutu popularnost testiranja učinaka tretmana i posljedica (ne)donošenja nekih značajnijih ekonomskih ili političkih promjena/odluka i slično. Kod modela sa slučajnim efektima se obrađuje GLS metoda procjene (engl. *Generalized least squares*), no kako se ona detaljnije obrađivala u poglavlju 4, ovdje se napominje što čitatelj treba ponoviti iz tog poglavlja (dano je u fusnoti). Na taj način kroz tekst autor olakšava čitatelju snalaženje u učenju. Tu su dalje obrađena potpoglavlja kako odabrati adekvatan model (standardni Hausmanov test za usporedbu modela s fiksnim i slučajnim efektima), *goodnes-of-fit* modela te kako provesti testiranje robusnosti inferencije. Kao primjer prikazan je Fama-MacBeth pristup testiranja CAPM modela nad panel podacima te mikroekonomski model faktora koji utječu na pojedinačne plaće. Potom su prikazani dinamički modeli, s opisom korak po korak GMM metode za procjenu parametara i Arellano-Bond procjeniteljem. Autor je uočio u praksi da se često javlja problem odabira prevelikog broja instrumentalnih varijabli kada se koriste u procjenama modela s panel podacima. Stoga jedno potpoglavlje komentira isključivo taj problem, gdje se daju savjeti što učiniti (kako izvršiti korekcije procjenitelja i koju literaturu dalje mogu proučavati). Kako se u ovome poglavlju radi o nešto složenijim temama, primjer koji se obrađuje na kraju

(kapitalna struktura poduzeća) obrađen je detaljno na više od 5 stranica. Kako su s vremenom produljile se vremenske serije i panel podataka, razvijeni su modeli testiranja jediničnih korijena i u tom slučaju. Tako su u knjizi obrađeni testovi prve i druge generacije, uz opsežan popis daljnje literature gdje se pojedinačno testovi raspravljaju s obzirom na njihove prednosti i nedostatke. Kako se u vremenskim serijama nakon testiranja (ne)stacionarnosti obrađivala kointegracija, tako se i ovdje spominje nakon spomenutih testova. Međutim, kako se radi o složenijoj analizi, autor daje nekoliko komentara i upućuje čitatelja na daljnju literaturu koja se ovime bavi, a može se uočiti da u posljednjih nekoliko godina se značajnije širi literatura u području panel kointegracije. Uvodno se obrađuju i *logit*, *probit* i Tobit panel modeli; a nekoliko stranica je posvećeno i nebalansiranim panelima i kako postupiti u tom slučaju (uz popis daljnje literature s obzirom na, ponovno, složenost materije u odnosu na prethodna poglavlja). Na samome kraju poglavlja dan je i uvod u pseudo-panel podatke, kada istraživač ima problema s prikupljanjem istih jedinica promatranja tijekom vremena. Autor preporuča korištenje instrumentalnih varijabli u nekim slučajevima, te ponovno navodi dodatnu literaturu. Može se uočiti u ovome poglavlju kako teme postaju složenije i stoga se pronalazi veći broj dodatne literature koju je potrebno dalje konzultirati. Stoga za analizu panel modela ova knjiga može poslužiti kao osnovica za naučiti osnovne pojmove, a dalje sam autor preporuča knjige poput Wooldridge (2010), Baltagi (2013), Hsiao (2014) ili Pesaran (2015).

Zaključno, temeljem analize sadržaja ove knjige, može se zaključiti da je namijenjena svima koji kreću s učenjem ekonometrije i koji žele nadograditi postojeće znanje. Stoga bi se mogla klasificirati u početničku do srednje zahtjevnu razinu prema težini materije jer obuhvaća i temeljna znanja koja je najprije potrebno savladati, kao i određene nadogradnje za analizu mikro podataka i vremenskih serija. Svako poglavlje popraćeno je brojnim primjerima, često i opsežnim, čime čitatelj može lakše savladati prethodno obrađivanu teoriju. Knjiga daje općenit prikaz nekoliko popularnih pristupa primijenjene ekonometrije. Nešto temeljitiji temelji dani su u prvih sedam poglavlja knjige, a ostala poglavlja daju osnovicu koju je najprije nužno savladati prije prelaska na reference koje sam autor preporuča za dalje. Kako se obrađuje metodologija za mikro i makro razinu, knjiga se preporuča svim pojedincima koji provode empirijska istraživanja u poslovanju i znanstvenom istraživanju.

Literatura:

- Baltagi, B. H. (2013). *Econometric Analysis of Panel Data*, 5th edition, John Wiley and Sons, Chichester, UK.
- Cumming, G. (2012). *Understanding The New Statistics: Effect Sizes, Confidence Intervals, and Meta-Analysis*, Routledge, New York, NY.
- Hamilton, J. D. (1994). *Time Series Analysis*, Princeton University Press, Princeton, NJ.
- Hsiao, C. (2014). *Analysis of Panel Data*, 3rd edition, Cambridge University Press, Cambridge, New York, NY.
- Larcker, D. F., Rusticus, T. O. (2010). On the Use of Instrumental Variables in Accounting Research, *Journal of Accounting and Economics*, Vol. 49, str. 186–205.
- Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*, Springer-Verlag, Berlin, Germany.
- Pesaran, M. H. (2015). *Time Series and Panel Data Econometrics*, Oxford University Press, Oxford, UK.
- Tsay, R. S. (2014). *Multivariate Time Series Analysis: With R and Financial Applications*, John Wiley and Sons, Chichester, UK.
- Wasserstein R. L., Lazar, N. A. (2016). The ASA's Statement on p-Values: Context, Process and Purpose, *The American Statistician*, Vol. 70, str. 129–133.
- Wooldridge, J. M. (2010). *Econometric Analysis of Cross-Section and Panel Data*, 2nd edition, MIT Press, Cambridge, MA.