CORE
Metadata, citation and similar papers at core.ac

Applied Econometric Time Series

PRIKAZ KNJIGE

Walter Enders
Hoboken, NJ: Wiley, 2010, treće izdanje, 531 str.

Essentially, all models are wrong, but some are useful.
George E. P. Box

Analiza vremenskih serija metoda je koja se koristi u širokom spektru društvenih znanosti. Svoju je primjenu pronašla prvenstveno u makroekonomiji i mikroekonomiji te financijama, ali se u posljednje vrijeme sve češće koristi i u politološkim i sociološkim istraživanjima. U tim se disciplinama istraživači početnici često suočavaju s nedovoljnim znanjem o metodama istraživanja. Stoga im je potrebna literatura koja će im pomoći da provedu empirijsko istraživanje, a da se pri tome ne izgube u statističkoj i ekonometrijskoj teoriji. Iskusniji istraživači pak često traže tekst koji bi novim tehnikama istraživanja osvježio i nadogradio njihovo znanje. Kako se analiza vremenskih serija ponekad koristi i u financijskim institucijama, prvenstveno pri procjeni rizika, zaposlenici bez formalnog obrazovanja o vremenskim serijama trebaju tekst koji će ih relativno brzo i jednostavno uvesti u problematiku. Uz navedene korisnike, tu su i studenti preddiplomskih i poslijediplomskih studija koji se specijaliziraju za ekonometrijsku analizu vremenskih serija. Upravo na tu vrlo široku publiku cilja posljednje - treće - izdanje Endersove knjige *Applied Econometric Time Series*. Široka publika je zagarantirana, jer da bi se gradivo moglo pratiti bez poteškoća potrebno je samo vrlo dobro poznavanje linearne regresijske analize i osnova matrične algebre. Prema tome, čitatelj se neće izgubiti u izvodima i dokazima kao što je često slučaj kod nekih naprednijih tekstova

(primjerice Hamilton, 1994 ili Lütkepohl, 2005), ali bez dobrog poznavanja osnova ekonometrije nije moguće neometano pratiti gradivo.

Kao što sam naziv kaže, riječ je o udžbeniku primijenjene ekonometrije. Sam autor u predgovoru navodi kako vrlo ozbiljno shvaća termin *primijenjeno* u naslovu. I toga se pridržava kroz cijelu knjigu. Prema tome, uz teoretska objašnjenja, knjiga obiluje primjerima i zadacima za vježbu, koji omogućavaju čitatelju lakše shvaćanje gradiva. Enders gradivo tumači na sebi svojstven način i u većini slučajeva pojednostavljuje kompleksne modele kroz nekoliko nužnih koraka (*step-by-step* i *general to specific procedure*), pri čemu se ni najmanje ne gubi na točnosti i svojstvima modela. Drugim riječima, radi se o *kuharici* za ekonometriju, ali u Endersovom slučaju to nipošto nema negativan prizvuk. Važan su dio takvog udžbenika i teoretska objašnjenja. Međutim, Enders prezentira teoriju isključivo s jednim ciljem: kako bi pojasnio izlaganje i olakšao razumijevanje. Izostavljeni su svi dijelovi koji ciljanoj publici nisu od interesa. Upravo zbog toga, njegov udžbenik zauzima posebno mjesto na prilično zasićenom tržištu udžbenika primijenjene ekonometrije.

Ekonometrija vremenskih serija izuzetno je široko područje te je na nešto više od 500 stranica gotovo nemoguće kvalitetno pokriti sve teme. Knjiga ima ukupno sedam poglavlja, a prvo je u potpunosti posvećeno diferencijskim jednadžbama za koje autor navodi da su temelj cijeloga teksta. Preostalih šest poglavlja obrađuje šest velikih tema iz analize vremenskih serija, pri čemu je svako organizirano na logičan i razumljiv način. Poglavlja završavaju sažetkom, odnosno zaključkom, nakon čega slijede pitanja i zadaci. Iako je svako poglavlje zasebno, za potpuno razumijevanje gradiva potrebno je čitati knjigu od početka, po mogućnosti bez preskakanja. To se pogotovo odnosi na neke povezane cjeline, poput vektorske autoregresije (poglavlje 5) i kointegracije (poglavlje 6). Također, nelinearni se modeli teško mogu pratiti zasebno, bez da je apsolvirano prethodno gradivo. Potrebno je naglasiti još dvije stvari koje značajno povećavaju korisnost ovog udžbenika. Prvo, s autorove mrežne stranice moguće je preuzeti dopunske materijale (*Supplementary manual*) koji dopunjuju osnovni tekst i obrađuju dodatne teme koje autor smatra važnima, ali ih je isključio iz

osnovnog teksta[1]. Drugo, profesori koji udžbenik koriste u nastavi, mogu upotrijebiti i nastavničke materijale (*Instructors' manual*) koji sadrže rješenja svih zadataka u knjizi te programski kod za EViews, RATS[2], SAS i Statu. Također, svi korišteni podaci mogu se preuzeti na Endersovoj mrežnoj stranici. Prema tome, knjiga zapravo obrađuje nešto širi spektar tema, a rješenja zadataka mogu se provjeriti što uvelike olakšava učenje.

Prvo je poglavlje posvećeno diferencijskim jednadžbama, pri čemu je fokus na onim metodama koje se koriste u analizi vremenskih serija. Analiziraju se samo sustavi s jednom jednadžbom, a naglasak je na različitim metodama njihova rješavanja. Iako je ovo poglavlje najmanje primijenjeno, primjeri olakšavaju shvaćanje i praćenje izlaganja. Bitno je napomenuti da se autor u kasnijim poglavljima poziva na neke elemente koji su uvedeni u ovome dijelu (primjerice u 2. i 4. poglavlju). Prema tome, preskakanje ovoga poglavlja nije najbolja strategija.

U drugom poglavlju Enders uvodi ključne koncepte za analizu vremenskih serija. Stabilnost diferencijskih jednadžbi povezuje sa stacionarnošću kao temeljem za analizu vremenskih serija. Ovdje se uvodi jednostavan ARMA model te se objašnjavaju alati za odabir adekvatnog modela (ACF, PACF i informacijski kriteriji). Osim što u ovome poglavlju koristi ARMA model da bi objasnio prognoziranje, autor također objašnjava nešto noviju problematiku nestabilnosti procijenjenih parametara i strukturnih prekida. Tako na vrlo zanimljivim primjerima prezentira rekurzivnu analizu i CUSUM test.

Treće je poglavlje vjerojatno najinteresantnije onima koji se bave analizom financijskih tržišta, budući da je njegova tema modeliranje volatilnosti. Poglavlje započinje opisom tzv. stiliziranih činjenica o vremenskim serijama, odnosno utvrđivanjem postojanja trenda, promjenjive varijance

---

[1] *Za dopunske materijale i serije podataka korištene u knjizi vidjeti http://old.cba.ua.edu/~wenders/applied-econometric-time-series/3rd-edition (pristupljeno 15. listopada 2012.)*

[2] *Za korisnike RATS-a programski je kod za sve zadatke javno dostupan na mrežnoj stranici Estime. Rješenja nisu dostupna samo nastavnicima već i svima ostalima. Vidjeti http://www.estima.com/cgi-bin/bookbrowser_singlebook.cgi?Textbook=enders (pristupljeno 15. listopada 2012.).*

(heteroskedastičnosti) te ostalih svojstava. Nakon toga, u poglavlju se razvija najjednostavniji model za modeliranje volatilnosti, tzv. ARCH koji se generalizira i nadopunjuje (GARCH, IGARCH, TARCH i EGARCH). Poglavlje završava multivarijatnim GARCH modelom, kao nadogradnjom osnovnog modela. Osim procjene modela, naglasak je i na prognoziranju budući da je investitorima volatilnost financijske imovine interesantna samo kroz tekuće i buduće razdoblje. Povijesno kretanje volatilnosti nije im od primarnog interesa.

Četvrto poglavlje sažima rezultate tzv. revolucije testova jediničnog korijena. Poglavlje započinje na prilično inovativan način: pomoću Grangerovog i Newboldovog eksperimenta pokazuje se zbog čega je uopće došlo do razvoja testova jediničnog korijena. Nakon toga se uvode Dickey-Fullerov test i sva njegova proširenja. Rasprava se nastavlja u smjeru snage testa i prikaza ostalih snažnijih testova jediničnog korijena. Vrlo su interesantni Monte Carlo eksperimenti pomoću kojih Enders objašnjava distribucije različitih testova. Takav pristup ima dvije prednosti. Prvo, na vrlo jednostavan način objašnjava složenu tehniku Monte Carlo eksperimenata. Drugo, jednom kada se shvati mehanizam djelovanja Monte Carlo eksperimenata, mnogo je jednostavnije shvatiti složenu problematiku vezanu uz testove jediničnog korijena. Konačno, dodatak ovome poglavlju pokriva *bootstrapping*, kao varijaciju Monte Carlo eksperimenata. Kombinacija temeljnih metoda u analizi vremenskih serija te spomenutih naprednijih alata čini ovo poglavlje temeljem za razumijevanje ostatka gradiva.

U petom su poglavlju obrađeni modeli s više jednadžbi. Najveći naglasak stavljen je na modele vektorske autoregresije (VAR modele). Na vrlo jednostavan i razumljiv način objašnjen je reducirani oblik sustava i popularna dekompozicija Choleskoga. Osim toga, obrađene su i različite strukturne dekompozicije (SVAR) s kratkoročnim i dugoročnim ograničenjima koja proizlaze iz ekonomske teorije. Detaljno su objašnjeni i alati koji se koriste u VAR analizi, odnosno Grangerova kauzalnost, funkcija impulsnog odaziva i dekompozicija varijance. Sve je potkrijepljeno primjerima pa je interpretacije jednostavnije razumjeti. Naime, u domaćim se radovima katkada može vidjeti kako se rezultati VAR modela pogrešno

interpretiraju. Ova knjiga omogućava da se takve pogreške izbjegnu. Osim VAR modela, ovo poglavlje obrađuje i nadogradnje ARIMA modela u vidu intervencijske analize i analize pomoću transferne funkcije (*intervention analysis* i *transfer function analysis*).

Unatoč tome što neki udžbenici iz ekonometrije vremenskih serija paralelno obrađuju VAR modele i kointegraciju (primjerice Lütkepohl i Krätzig, 2004), Enders se odlučio razdvojiti ova dva modela, što je zapravo dobar izbor. Tako je kointegracija zaseban predmet šestog poglavlja. Ukupno se obrađuju tri modela kointegracije: Engle-Grangerov, Johansenov i ADL kointegracija (*autoregressive distributed lag*). Unatoč tome što se kointegracija na prvi pogled može učiniti vrlo neintuitivnim i matematički vrlo zahtjevnim modelom, Enders to rješava na dva načina. Prvo, dovodi u vezu kointegraciju s testovima jediničnog korijena. Na taj se način gradi intuicija o tome što stoji iza modela pa izračuni jedinstvenih vrijednosti i jedinstvenih vektora dobivaju vrlo konkretan smisao. Drugo, odličnim izborom primjera ilustrira primjenu sva tri modela te time dodatno olakšava razumijevanje. Sveukupno, ovo je najbolje objašnjenje kointegracijskih modela koje sam do sada pročitao. U ovom je poglavlju važna i rasprava o diferenciranju podataka i početnom testiranju kointegracije. Naime, zaključak koji se može izvući iz ovoga poglavlja vrlo je jasan: ukoliko se kointegrirane varijable analiziraju u VAR modelu bez člana korekcije pogreške, tada je takav model pogrešno specificiran. To je također jedna od grešaka koju je moguće primijetiti u nekim empirijskim radovima.

Posljednje, sedmo poglavlje obrađuje relativno nove teme vezane uz nelinearne modele. Budući da je ovo područje brzorastuće, upravo je ovdje napravljeno najviše izmjena u odnosu na prethodno izdanje knjige. Ovo se poglavlje temelji na prethodnima, točnije obrađuju se nelinearni modeli čija su baza ARIMA modeli. Prema tome, procjena modela bazira se na metodi najmanjih kvadrata (OLS), metodi najveće vjerodostojnosti (ML) te metodi nelinearnih najmanjih kvadrata. Najviše se pozornosti pridaje autoregresivnom modelu s uključenim pragom (*threshold autoregressive* - TAR) i postupnim prijelazom (*smooth transition autoregressive* - STAR). Autor spominje kako je početno testiranje nelinearnosti prilično jednostavno.

Naime, gotovo da nije problem utvrditi postoji li nelinearna veza ili ne, problem je utvrditi stvarnu prirodu takve veze. Poglavlje završava raspravom o nelinearnim testovima jediničnog korijena.

Najveće su snage ovog udžbenika uglavnom već spomenute, to su: primjenjivost i fokusiranost. Što se tiče primjene, svako poglavlje uključuje po nekoliko stvarnih primjera, od kojih su neki vrlo aktualni i zanimljivi. Tako se može naći model burzovnog indeksa za NYSE kao ilustracija GARCH modela. Zatim su poslovni ciklusi i rasprave o determinističkom i stohastičkom trendu poslužili kao vrlo zanimljiva ilustracija testova jediničnog korijena. Pomoću pariteta kupovne moći ilustriraju se i testovi jediničnog korijena i kointegracija. No, nisu svi primjeri samo iz ekonomije. Kao ilustracija VAR modela poslužio je i utjecaj terorizma na španjolski turizam. Što se tiče slabosti knjige, može ih se navesti nekoliko. Najveća joj je zamjerka to što uopće nije dotaknuto pitanje narušavanja pretpostavki modela te kako korigirati takve modele. Naime, svi se istraživači susreću s praktičnim problemom prisutnosti autokorelacije ili heteroskedastičnosti reziduala. U knjizi nije objašnjeno što učiniti u toj situaciji ili u situaciji nenormalne distribucije reziduala. Za takva je pitanja potrebno konzultirati druge udžbenike. Kritika se također može uputiti i interpretaciji rezultata u nekim slučajevima. Naime, u pojedinim slučajevima Enders jednostavno ne posvećuje dovoljno mjesta interpretaciji dobivenih rezultata. S obzirom na to da je riječ o udžbeniku primijenjene ekonometrije, fokus ne bi trebao biti samo na procjeni modela. Međutim, slučajevi s manjkavom interpretacijom zaista su rijetki.

Treće izdanje ove knjige iz 2010. godine ipak predstavlja evoluciju, a nikako ne revoluciju u odnosu na prethodno izdanje iz 2004. godine. Naime, poglavlja od dva do šest proširena su s dodatnom točkom, pri čemu se obrađuju neke važne teme poput nestabilnosti procijenjenih parametara, strukturnih prekida, prognoziranja u GARCH modelima te rasprave o testovima jediničnog korijena i testovima kointegracije. Međutim, ukupna promjena ovdje nije značajno vidljiva. Daleko najveću reviziju doživjelo je posljednje, sedmo poglavlje o nelinearnim modelima, zbog kojeg vrijedi nabaviti novo izdanje.

Zaključno, *Applied Econometric Time Series* udžbenik je koji se neće samo jednom pročitati i zaboraviti. U primijenjenom empirijskom radu uvijek je potrebno imati izvor koji može poslužiti kako bi se podsjetili na određene metode, kako bi proučili detalje na koje nismo obraćali pozornost pri prvom čitanju ili najjednostavnije, izvor koji možemo citirati prilikom pisanja metodološkog dijela rada. Budući da ovaj udžbenik ima brojne prednosti, počevši od jasnoće izlaganja, primjenjivosti i velikog broja dodatnih besplatnih materijala, kupnjom ovog udžbenika ostvaruje se vrlo povoljan odnos uloženog i dobivenog. Drugim riječima, ovo je knjiga koju svatko tko se bavi vremenskim serijama jednostavno mora imati u svojoj biblioteci.

Literatura

Hamilton, Douglas J., 1994, *Time Series Analysis*, Princeton NJ: Princeton University Press.

Lütkepohl, Helmut, 2005, *New Introduction to Multiple Time Series*, Berlin: Springer-Verlag.

Lütkepohl, Helmut i Markus Krätzig, 2004, *Applied Time Series Econometrics (Themes in Modern Econometrics)*, Cambridge: Cambridge University Press.

Vladimir Arčabić
Ekonomski fakultet u Zagrebu