

2. NAVJEŠĆUJUĆI INDIKATORI HRVATSKOG GOSPODARSTVA

Uvod

Kada bi se uspjeh određenog pristupa ekonomske analize mogao mjeriti lakoćom razumijevanja i njegovom popularnošću, tada upotreba "sustava navješćujućih indikatora" (leading economic indicators) u prognostičke svrhe sigurno dolazi na sam vrh niza takvih uspjeha. Stoga ne iznenađuje činjenica da ovo istraživanje u brojnim razvijenim zemljama često dobiva status projekta kojeg trajno financira državna administracija.

Analitičku i prognostičku metodu poznatu kao "pristup indikatora" utemeljili su Wesley C. Mitchell i Arthur F. Burns još davne 1938. godine u okviru National Bureau of Economic Research¹. Tada je objavljena prva lista cikličkih indikatora američke privrede, na kojoj su se našle serije čiji se ciklički zaokreti podudaraju, prethode ili pak zaostaju za prijelomima u agregatnoj ekonomskoj aktivnosti (Moore i Shiskin, 1967). Čak niti jedan od najjačih kritičkih osvrtâ, kojeg je u samim počecima razvoja metode Koopmans (1947) uputio njezinim utemeljiteljima, nije diskreditirao popularnost niti spriječio širenje ove analitičke i prognostičke metode. O tome svjedoče dugogodišnji razvoj pristupa indikatora u okviru NBER-a i njegovo objavljivanje u brojnim stručnim i specijaliziranim publikacijama najrazličitijih ekonomskih institucija u svijetu².

¹ NBER - poznata američka znanstveno istraživačka institucija uključena u gotovo sva područja ekonomske znanosti. NBER-ova osnovna metodologija za analizu poslovnih ciklusa postala je "standardom" proučavanja ekonomskih fluktuacija svuda u svijetu.

² To su Bureau of Economic Analysis (BEA) pri US Department of Commerce, Department of Economics and Statistics pri OECD, Center for International Business Cycle Research (CIBCER) pri Columbia University, British Central Statistical Office, Economic Planning Agency u Japanu, itd.

Pristup kojem se godinama pripisuje svojstvo "mjere bez posebne ekonomske teorije" preživio je razdoblja u kojima se stavljao naglasak na predviđanje putem specificiranog makroekonometrijskog modela. S vremenom je ekonomska struka prihvatila sustav cikličkih indikatora kao vrlo praktičnu, ekonomičnu i, u metodološkom smislu, jednostavnu tehniku dobivanja jasne slike ekonomskog stanja iz gomile ekonomskih podataka. Brojna preispitivanja i ispravci utjecali su na izvjestan metodološki "preporod" pristupa indikatora krajem sedamdesetih i početkom osamdesetih godina. To je ujedno značilo povratak sustava navješćujućih indikatora među najpoznatije metode analize vremenskih serija (Auerbach, 1982).

1. O razvoju i obilježjima cikličkih indikatora

Fluktuacije u ekonomiji, te nagli zaokreti, ubrzanja ili usporavanja ekonomskih kretanja predstavljaju ekonomsku realnost koju su ljudi vrlo rano počeli zapažati. Stoga već više od jednog stoljeća ekonomska struka gaji dvojak interes za takva zbivanja: teorijski i empirijski.

Prvi je rezultirao brojnim definicijama cikličkih obilježja gospodarstva i potragom za pokretačima ekonomskih fluktuacija. Koliko je taj interes bio snažan svjedoče brojne teorije o poslovnim ciklusima koje su nastajale na uporištima najpoznatijih ekonomskih doktrina (Niemira i Klein, 1994; Zarnowitz, 1992).

Empirijska su istraživanja od samih početaka pratila nastanak teorija o poslovnim ciklusima i pomagala u testiranju znanstvenih postavki i objašnjenja. No, tek kada su uslijedili jači ekonomski poremećaji i "šokovi", koji su između dva svjetska rata bivali sve snažniji, praćenje fluktuacija u ekonomiji dobiva sasvim nove, šire dimenzije. U takvim nestabilnim i neizvjesnim vremenima započela je potraga za indikatorima kojima bi se mogli barem približno nagovijestiti prijelomi u ekonomskoj

aktivnosti³.

Prvi sistematičan i ozbiljniji pristup izgradnji takvog sustava indikatora uslijedio je 1937. godine. Vlada SAD obratila se istraživačima NBER-a s molbom da izrade sustav pokazatelja koji bi signalizirali događaje i poremećaje u ekonomiji. Osim glavnih istraživača Mitchella i Burnsa, u istraživanjima o ciklusima sudjelovali su i drugi poznati ekonomisti: Moses Abramovitz, Milton Friedman, Gottfried Haberler i Geoffrey Moore. Nakon njihovih prvih pokušaja uslijedile su brojne revizije što je do današnjih dana rezultiralo golemim napretkom u razvoju ove analitičke i prognostičke metode⁴.

Sustav navješćujućih (vodećih, prethodećih) **indikatora** čine izabrane vremenske serije koje **vlastitim prijelomima u kretanju nekoliko mjeseci unaprijed najavljuju zaokret globalne ekonomske aktivnosti** ili pak dijelova ekonomije. Izbor navješćujućih pokazatelja slijedi nakon detaljne analize obrazca ponašanja brojnih ekonomskih serija čijim kretanjem dominira ciklička komponenta. Riječ je o specifičnom metodološkom postupku kojim je, uz navješćujuće pokazatelje, moguće izdvojiti i tzv. **prateće indikatore** (serije koje zaokreću gotovo istovremeno kad i globalna aktivnost) i **zaostajuće indikatore** (serije koje reagiraju na promjene u ekonomiji naknadno).

No, činjenica je da se jedino uvidom u dinamiku navješćujućih pokazatelja može najaviti kretanje promatrane makroekonomske veličine. Stoga se ovaj prognostički pristup, popularno nazvan **barometarsko**

³ *Potruga za takvim ekonomskim indikatorima započinje još 20-tih godina ovog stoljeća, kada se pojavljuju poznate Harvard ABC krivulje, objavljene prvi put 1919. godine (Granger, 1989). Ovim se krivuljama analiziralo kretanje uglavnom financijskih pokazatelja. Cilj je bio otkriti serije sa izrazito cikličkim obrascem ponašanja, što bi pomoglo u predviđanju ekonomskih izgleda u skoroj budućnosti. No, česti poremećaji i nestabilnost tržišta novca i kapitala uskoro su poljuljali povjerenje u financijske pokazatelje kao potencijalne indikatore općih ekonomskih kretanja.*

⁴ *O položaju ove metode u grupi poznatih prognostičkih pristupa, te o njezinom povijesnom razvoju vidjeti detaljnije u: Ahec-Šonje (1995b).*

predviđanje, temelji na izradi i usavršavanju sustava vodećih, odnosno navješćujućih indikatora.

Ne treba zanemariti činjenicu da kratkoročno prognoziranje sustavom indikatora privlači sve veću pažnju u svim ekonomskim krugovima u svijetu. U SAD ovo istraživanje dobiva status povlaštenog državnog projekta, čijim se rezultatima koristi čak i američka vlada pri provođenju kratkoročne ekonomske politike. Svoju popularnost ova metoda može zahvaliti primjeni relativno jednostavnih metodoloških postupaka prilikom izbora navješćujućih indikatora. Još se jednostavnijom čini tehnika izračunavanja njihovih zajedničkih mjera poput složenog ili kompozitnog indeksa tih pokazatelja. Stoga je ova metoda poznata i po lakoći kojom se tumače dobiveni prognostički iskazi. Prednost pristupa indikatora sastoji se i u njegovoj visokoj informativnosti, jer sustav polazi od najšire moguće baze podataka i pruža informacije o gotovo svim aspektima ekonomskog života.

Budući da je ovaj prognostički pristup manje poznat domaćoj ekonomskoj javnosti, namjera je da se u ovom članku rezimiraju prvi dosadašnji rezultati njegove primjene u uvjetima hrvatskog gospodarstva. Zbog ograničenosti prostora ovaj rad predstavlja tek vrlo kratak osvrt na izvorne metodološke korake izbora i izračunavanja složenog indeksa navješćujućih indikatora⁵. Najzanimljiviji dio rada zasigurno predstavlja analiza kretanja domaćeg navješćujućeg indeksa **CROLEI (CROatian Leading Economic Indicators)**. Ovaj se pokazatelj konstruira za potrebe prognoziranja ekonomskih kretanja u Hrvatskoj i temelji se na prvom domaćem sustavu navješćujućih indikatora.

Ozbiljnije istraživanje metode i njezinih teorijskih osnova uslijedilo je tek polovicom 1994. godine⁶, dok se izračunavanju prvog domaćeg

⁵ *Detaljan prikaz izvorne metodologije sa svim dosadašnjim dopunama i revizijama vidjeti u magistarskom radu: Ahec-Šonje (1995a).*

⁶ *Među prvim radovima nastalim u okviru istraživanja indikatora hrvatskog gospodarstva vidjeti projektnu dokumentaciju: Ahec-Šonje et al. (1994).*

prognostičkog iskaza (CROLEI) pristupilo tijekom 1995. godine⁷, u bitno drugačijim ekonomskim i institucionalnim uvjetima od onih u kojima je metoda dugo godina nastajala. Stoga, sve dok se ne postigne određena zrelost i iskustvo u istraživačkom smislu, ne trebaju nas iznenaditi povremeni metodološki posrtaji, niti mogućnost pojave povremenih krivih signala o kretanju domaće ekonomske aktivnosti.

2. Metodologija

Od samih početaka njezina razvoja ova metoda naglašava snažnu vezu navješćujućih indikatora i globalne ekonomske aktivnosti (ili izabrane referentne serije) u blizini cikličkih zaokreta, a ne toliko u drugim dijelovima ciklusa⁸. Stoga se ovim pristupom pretežno analizira ponašanje navješćujućih indikatora oko prijelomnih cikličkih točaka. Dosadašnji istraživački naponi bili su primarno usmjereni na ocjenjivanje pojedinih ekonomskih serija i tumačenje dobivenih složenih indeksa navješćujućih pokazatelja.

Vremenske su serije dobri "leaderi" ako se utvrdi da njihov zaokret prethodi zaokretu globalne ekonomske aktivnosti. Međutim, uvijek postoji određena nesigurnost u određivanju stvarnog trenutka zaokreta aktivnosti. Jedan neformalan pristup u tumačenju složenih indeksa sugerira da će tri uzastopna pada mjesečnog indeksa navješćujućih

⁷ CROLEI pokazatelj objavljuje se tek posljednjih mjeseci 1995. godine u Mjesečnom statističkom prikazu Ministarstva financija Republike Hrvatske, koje od samog početka potiče ovo istraživanje.

⁸ Postoje različite definicije poslovnih ciklusa. NBER-ova metoda polazi od klasične definicije koju su njeni utemeljitelji Mitchell i Burns uveli još 1946. godine (Lahiri i Moore, 1991), a koja skraćeno glasi: "Poslovni su ciklusi vrsta agregatne ekonomske aktivnosti u gospodarstvima temeljenim na tržišnim principima; ciklus se sastoji od faze ekspanzije koja se gotovo istovremeno zbiva u većini ekonomskih aktivnosti, a koju slijede faza recesije, kontrakcije i faza oporavka koja se stapa u novu fazu ekspanzije sljedećeg ciklusa; taj slijed promjena se uvijek iznova ponavlja iako ne u pravilnim vremenskim razmacima. Vremenska dimenzija poslovnih ciklusa varira od jedne do deset ili čak dvanaest godina;....".

indikatora signalizirati zaokret ekonomskih agregata nadalje. No, istraživači i dalje postavljaju ključno pitanje: kada do prijeloma u kretanju agregata stvarno dolazi? Da li se radi o dva, tri ili pak šest mjeseci nakon najave pomoću navješćujućih pokazatelja? To su pitanja koja su podijelila istraživače, premda oni pokušavaju usuglasiti svoje stavove i najnovijim istraživanjima riješiti te dileme. Osim ove poteškoće neki istraživači smatraju da se ovim pristupom zanemaruju diskretne promjene navješćujućih indikatora prije i nakon prijelomnih točaka (Neftci, 1979). Premda izazivaju interes, ovi problemi nadilaze ciljeve ovog rada, jer predstavljaju novije empirijske izazove za istraživače poslovnih fluktuacija.

Premda se NBER metodologija odlikuje jednostavnošću u tumačenju dobivenih prognostičkih iskaza, riječ je ipak o opsežnom i detaljima bogatom analitičkom zadatku. U ovom se poglavlju daje skraćeni prikaz svih metodoloških koraka koji će zainteresiranom čitatelju pružiti zaokruženu sliku o metodi⁹. Pritom će se uvijek naglasiti u kojim su dijelovima izvršene nužne metodološke prilagodbe domaćim ekonomskim uvjetima.

O PODACIMA

Potruga za navješćujućim indikatorima počinje izgradnjom sveobuhvatne baze podataka, koje prikupljaju i objavljuju službena statistika i druge državne institucije. Pritom treba voditi računa da sve serije imaju **isti i što duži vremenski obuhvat**. Kvalitetne metodološke napomene i objašnjenja olakšavaju korištenje tih podataka i pružaju istraživačima značajne informacije o promatranim serijama. Poželjno je raspolagati ekonomskim serijama kod kojih se postiže maksimalna ažurnost u prikupljanju i objavljivanju, te onima sa jednostavnim metodološkim objašnjenjem.

⁹ Detaljan prikaz metode čitatelj će naći u: Moore i Shiskin (1967), Niemira i Klein (1994) i Ahec-Šonje (1995a).

Kako treba izgledati sveobuhvatna i kvalitetna baza podataka pokazuje **Handbook of Cyclical Indicators** (U.S. Department of Commerce, 1977). To je priručnik i dodatak mjesečnoj publikaciji **Business Condition Digest** u kojem se objavljuje preko 300 različitih vremenskih serija grupiranih u prethodeće, prateće i zaostajuće pokazatelje. O opsežnosti ove baze svjedoči dugačak vremenski obuhvat svih objavljenih serija, koji iznosi čak 30 godina (razdoblje od 1945. do 1975. godine).

Dosadašnji istraživački naponi u RH rezultirali su statističkom bazom od oko 150 vremenskih serija koje pokrivaju gotovo sva relevantna područja hrvatskog gospodarstva¹⁰. Međutim, već se na samom početku izgradnje domaće statističke podloge uočilo da ne postoji jedinstvena, dovoljno ažurna i lako dostupna baza koja bi zadovoljila sve potrebne stručne kriterije.

Zasigurno najtežu prepreku u primjeni metode predstavlja prekratak vremenski obuhvat ekonomskih serija. Naime, odluku o vremenskom obuhvatu otežali su uvjeti s kojima se suočilo hrvatsko gospodarstvo posljednjih nekoliko godina. Osnovna je dilema bila: zadovoljiti NBER-ov zahtjev o korištenju što dužih serija i time izabrati razdoblje 20-30 godina unatrag, ili uvažiti činjenicu da se gospodarskim i političkim osamostaljenjem Hrvatske mijenjaju uvjeti koji bitno utječu na primjenjene tehnike i rezultate analize.

Stoga nije potrebno posebno naglašavati razloge zašto je istraživački tim odustao od prvog rješenja. Gospodarska i politička samostalnost Hrvatske smatra se osnovnim preduvjetom za ispravno uočavanje veza između standardne ekonomske analize i stvarnosti. Zato se ekonomski pokazatelji domaće baze prate od siječnja 1991. godine, što je otežalo, ali ne i

¹⁰ To su serije klasificirane u sljedeće ekonomske grupacije: 1) industrijska proizvodnja, 2) zaposlenost i neto plaće, 3) nezaposlenost i zapošljavanje, 4) graditeljstvo i turizam, 5) trgovina i poljoprivreda, 6) šumarstvo i prijevoz, 7) vanjska trgovina, 8) nefinancijske transakcije, 9) novac i krediti, 10) tržište novca i ostali monetarni pokazatelji, 11) prihodi i rashodi državnog proračuna, 12) ostali grupirani pokazatelji, (Ahec-Šonje, 1995a).

spriječilo primjenu standardnog metodološkog aparata. S obzirom da se radi o prvim pokušajima primjene ove poznate metode, čak ni sve navedene primjedbe ne mogu umanjiti značaj započete izgradnje efikasnog domaćeg sustava navješćujućih indikatora. Svakim novim mjesečnim ažuriranjem ti problemi bivaju sve manji i olakšavaju zadatak domaćem istraživačkom timu.

O PROBLEMIMA IZBORA REFERENTNE SERIJE

Prvo pitanje s kojim se istraživači susreću je kako i čime mjeriti stanje u ekonomiji. Pritom se utvrđuje koncept agregatne ekonomske aktivnosti, odnosno vremenska serija čiji se smjer i dinamika kretanja navješćuje. Najpoznatiji makroekonomski agregat je bruto domaći proizvod (BDP), koji se među prvima počeo koristiti kao referentna serija. Međutim, kada su isplivali svi problemi poput složenosti i neažurnosti u prikupljanju, te veliki troškovi utvrđivanja tog agregata, istraživači se odlučuju za mjesečne indekse industrijske proizvodnje¹¹.

Premda industrijska proizvodnja ne obuhvaća značajne dijelove ekonomske aktivnosti (poljoprivreda i usluge), postoje opravdani razlozi za njezin izbor. U tržišnim ekonomijama većinu industrijskih sektora karakterizira snažna ciklička komponenta u obrazcu kretanja i visoka osjetljivost na promjene u drugim dijelovima ekonomije. Osim toga, cikličke oscilacije "neindustrijskih" sektora (posebno usluga) često su usko povezane sa onima u industriji. Činjenica je da se, primjerice, kod nekih članica OECD-a ciklus u industriji gotovo poklapa sa cikličkim obrazcem BDP-a, pa se dobiveni složeni indeks navješćujućih indikatora za industriju može koristiti za prognoziranje oba dviju referentnih serija.

¹¹ *Primjerice, Department of Economics and Statistics pri OECD koristi mjesečne indekse industrijske proizvodnje. Premda su u počecima koristili koncept BDP-a, uvidjelo se da samo polovica zemalja članica prati ovaj agregat kvartalno, a ostali tek na godišnjoj razini. Osim toga, neke troškovne komponente BDP-a kod zemalja OECD-a nisu cikličkog karaktera ili su pak kontracikličke, poput budžetskih izdataka, potrošnje stanovništva, dijela investicija, itd. (OECD Department of Economics and Statistics, 1987).*

Izbor referentne serije često ovisi i o specifičnom istraživačkom cilju. Ukoliko se nastoji izgraditi sustav navješćujućih indikatora za, primjerice, monetarni segment ekonomije, u tom slučaju referentnu seriju predstavljaju jedan ili više monetarnih agregata.

Premda je bio i još uvijek je problem čime mjeriti ekonomsko stanje u Hrvatskoj, pronađeno je relativno zadovoljavajuće rješenje. Svjesni svih argumenata za i protiv korištenja industrijske proizvodnje kao ključne referentne serije, pristupilo se izradi navješćujućih indikatora upravo tog ekonomskog segmenta. Stoga primjenu metode nije spriječila čak niti sporost Državnog zavoda za statistiku u razradi i preuzimanju sustava društvenih računa (SNA) prema metodologiji UN-a. Izbor industrijske proizvodnje ne umanjuje vrijednost prognostičkog iskaza, ali se zahtijeva povećani oprez pri tumačenju dobivenih rezultata.

"SCORING" ILI OCJENJIVANJE VREMENSKIH SERIJA

"Scoring" služi za testiranje kvalitete vremenskih serija kao indikatora cikličkog kretanja ekonomske aktivnosti, bez obzira da li se radi o navješćujućim, pratećim ili zaostajućim pokazateljima. Ovaj postupak omogućuje istraživačima temeljit uvid u ponašanje promatranih serija, a to olakšava interpretaciju njihovih tekućih vrijednosti. **Osnovni cilj "scoring" metode je procjena uloge i ponašanja vremenskih ekonomskih serija u poslovnom ciklusu, a time i njihove upotrebljivosti u analitičke i prognostičke svrhe.**

Prvi "scoring" plan ili postupak ocjenjivanja serija izradili su Mitchell i Burns još davne 1938. godine. Interesantno je da se kriteriji ocjenjivanja koje su definirali ovi autori koriste do današnjih dana, što potvrđuje svu ozbiljnost kojom su pristupili razvoju ove "nemodelske" tehnike prognoziranja. Cijeli "scoring" sustav počiva na njihovim prvim razmišljanjima o obilježjima "idealnog" navješćujućeg indikatora, koji treba: pokrivati gotovo pola stoljeća; najavljujati ciklički oporavak barem tri mjeseca unaprijed; biti "izgladen", bez hirovitih i nepredvidivih oscilacija, sa vidljivim i lako uočljivim cikličkim kretanjem; treba biti

usko povezan sa kretanjem opće ekonomske aktivnosti; treba ga biti moguće jednostavno i brzo ažurirati uz dobro i kvalitetno uklanjanje sezonske komponente iz vremenske serije.

Uz osnovni zahtjev da navješćujući indikator pri cikličkom zaokretu prethodi referentnoj seriji, poželjno je da ciklički "profil" bitno ne odstupa od "profila" referentne serije. To omogućuje da se zaključci o nadolazećem ciklusu donose na temelju amplitude navješćujućeg indikatora i snage njegove cikličke komponente. Na temelju navedenih poželjnih obilježja vodećih indikatora Mitchell i Burns definirali su osnovne kriterije za ocjenu upotrebljivosti serija u analitičke i prognostičke svrhe:

- 1) ekonomska značajnost (signifikantnost) serije
- 2) statistička pouzdanost serije
- 3) usklađenost kretanja serije i opće ekonomske aktivnosti
- 4) vremenska konzistentnost indikatora
- 5) izglađenost serije
- 6) ažurnost statističke podloge.

Ključni kriterij pri izboru pokazatelja je **ekonomska značajnost** serije. Indikatori koji se izabiru iz ogromne baze podataka moraju predstavljati ključne aktivnosti u cikličkom procesu. Ovaj kriterij donosi istraživačima najveće poteškoće, jer ne postoji objektivni i kvantitativni postupak ocjene ekonomske značajnosti. Da bi se procjenio ekonomski značaj serije u cikličkom kretanju globalne aktivnosti potrebno je odgovoriti na sljedeća pitanja:

- a) kakva je uloga promatrane serije u globalnoj aktivnosti?
- b) da li ta serija dovoljno široko obuhvaća ekonomski proces kojeg predstavlja?

Kvaliteta odgovora ovisi prije svega o iskustvu i umješnosti prosuđivanja istraživača o prednostima i nedostacima usko ili široko definiranih indikatora. Znamo da kod agregata teže dolazi do nepredvidivih i hirovitih oscilacija, što nije rijedak slučaj kod uže definiranih indikatora

(podagregata). Stoga je jasno da se prednost i najveća ocjena prema ovom kriteriju daje ekonomskim agregatima.

Statistička pouzdanost vremenske serije ovisi o kvaliteti statističkih metoda prikupljanja podataka. Koliko pouzdano određena serija reprezentira ekonomsku pojavu ili proces u razmatranju? Odgovarajući na ovo pitanje istraživač procjenjuje kvalitetu statističkih izvora i ocjenjuje seriju s obzirom na:

- a) statistički obuhvat serije (cijela populacija ili uzorak),
- b) sustav izvještavanja (direktni ili indirektni),
- c) vremenski obuhvat podataka (mjesečni, kvartalni ili godišnji),
- d) učestalost promjena metodološkog obuhvata i mjera statističke greške,
- e) kvalitetu metodološkog objašnjenja,
- f) dužinu serije i usporedivost podataka u vremenu.

Stupanj usklađenosti kretanja indikatora i opće ekonomske aktivnosti nekada se mjerio pomoću tzv. "indeksa ujednačenosti" kretanja. To je bila vrsta koeficijenta korelacije između cikličkih fluktuacija promatrane serije i globalne ekonomske aktivnosti, koji je pokazivao koliko vjerno ta serija prati kronologiju poslovnih ciklusa¹². S obzirom da ova mjera zanemaruje pojavu ekstra ciklusa i ne vodi računa o amplitudi kretanja serije, NBER s vremenom ovaj indeks zamjenjuje novom mjerom usklađenosti. To je "mjera vjerojatnosti" koja pokazuje kolika je vjerojatnost da promatrana serija dostigne unaprijed utvrđenu potrebnu razinu "indeksa usklađenosti"¹³. Činjenica je da se radi o jednom od analitički najzahtjevnijih kriterija ocjenjivanja unutar "scoring" sustava. Za NBER to nije bio težak zadatak, jer već **desetljećima** prati kronologiju

¹² Serija koja pokazuje rast u razdoblju ekspanzije i pad u razdoblju recesije usklađena je sa kretanjem globalnog ciklusa i dobiva indeks +100 (ako se pak kreće u suprotnom smjeru indeks je -100).

¹³ O ovom i drugim kriterijima ocjenjivanja detaljnije vidjeti: Moore i Shiskin (1967). Dodatna objašnjenja i uputstva za izradu "scoring" tablice vidjeti: Ahec-Šonje (1995a).

poslovnih ciklusa i raspolaže s točno utvrđenim datumima zaokreta globalne aktivnosti.

Za ocjenu **vremenske konzistentnosti (timing)** pokazatelja u prethodjenju, praćenju ili zaostajanju za stvarnim ekonomskim pojavama, potrebno je utvrditi prosječnu "dužinu" ili broj mjeseci prethodjenja ili zaostajanja serije. Ne postoji jedinstveni "lead-lag time", a najčešći je slučaj da se sa svakim novim ciklusom ta dužina mijenja. I u ovom slučaju NBER izračunava kolika je vjerojatnost da serija koja pokriva poslovni ciklus **uglavnom** prethodi (prati ili zaostaje) cikličkom zaokretu. Izračunata veća mjera vjerojatnosti pruža i veću sigurnost pri klasifikaciji pokazatelja. S obzirom da ne postoji opravdan razlog da se serija ocjenjuje prema tome da li navješćuje zaokret 3, 4 ili 5 mjeseci unaprijed, NBER napominje da ovi podaci mogu poslužiti **samo** za klasifikaciju serija u navješćujuće, prateće ili zaostajuće indikatore. Da bi se ovaj, kao i prethodni kriterij ocjenjivanja, mogao kvalitetno primijeniti nužno je raspolagati dovoljno dugim vremenskim serijama. Ovim postaje jasno koji će se dijelovi izvorne metode morati zamijeniti pomoćnim tehnikama, da bi se omogućilo istraživanje navješćujućih indikatora hrvatskog gospodarstva.

Budući da postoji uska povezanost između **izgladenosti vremenske serije i ažurnosti statističke podloge**, ova se dva kriterija često promatraju zajedno. Brzo raspoloživi i lako dostupni podaci ostavljaju analitičaru dovoljno vremena za analizu i pripremu serije u prognostičke svrhe. Stoga serije kojima dominira sezonska i iregularna komponenta trebaju biti što "ažurnije", kako bi se postupak desezoniranja mogao izvršiti bez većih gubitaka u njihovom vremenu prethodjenja. Prednost se stoga daje serijama koje se objavljuju mjesečno, tjedno ili dnevno. Međutim, gubitak ažurnosti zbog izgladivanja vremenskih serija može se nadoknaditi izborom pokazatelja s dugim vremenom prethodjenja. Poznato je NBER-ovo stajalište da serije koje nisu ažurne, ali koje imaju dugi "lead time" (oko 6 mjeseci), mogu biti upotrebljivije za prognoziranje od ažurnih serija sa kraćim vremenom prethodjenja (oko 3 mjeseca). Stoga je poželjno da se tek nakon postupka "izgladivanja" vremenskih serija pristupi utvrđivanju "lead-lag" razdoblja svakog

pojedinih pokazatelja¹⁴.

Dugogodišnje iskustvo istraživača NBER-a nedvosmisleno sugerira da je najbolje od samih početaka pristupiti ocjenjivanju svake vremenske serije zasebno. Nakon što istraživački tim prihvati navedene kriterije, nužno je utvrditi **pondere značajnosti** svakog pojedinog kriterija ocjenjivanja. Koji će kriterij imati najveći utjecaj na ukupnu ocjenu indikatora, ovisi isključivo o procjeni istraživača. U prvim metodološkim papirima NBER-a prva četiri kriterija "težili" su po 20%, dok su izglađenost i ažurnost podataka dobili pondere značajnosti po 10% (Moore i Shiskin, 1967). Revizijom "scoring" sustava iz 1975. godine BEA pri US Department of Commerce (BEA/DOC) utvrđuje nove pondere značajnosti "scoring" kriterija (Zarnowitz i Boschan, 1975). Preporuka je NBER-a da se s vremenom provodi revizija utvrđenih pondera u skladu s promjenama ekonomskih uvjeta. Stoga, kod preuzimanja i primjene ove metode treba imati na umu da NBER/BEA ponderi značajnosti nisu pravilo, već oslonac u određivanju "težine" kriterija ocjenjivanja.

Svaka se promatrana ekonomska serija ocjenjuje bodovima od 0-100, s obzirom na svaki od navedenih kriterija. Ocjene dobivene na temelju svakog pojedinog kriterija "važu" se unaprijed zadanim ponderima značajnosti i zatim zbrajaju u jedinstvenu, ukupnu ocjenu promatrane serije. Indikatori s najvišom "prosječnom ocjenom" predstavljaju kandidate za izračunavanje složenog indeksa navješćujućih, pratećih ili zaostajućih pokazatelja.

¹⁴ Dekompozicija vremenskih serija upotrebom nekog od poznatih programa (primjerice, X11ARIMA - Statistics Canada) predstavlja pomoćnu metodu za ocjenu i izbor indikatora. Ocjena izglađenosti serije temelji se na rezultatima postupka sezonaliziranja, kao što su: odnos prosječne promjene iregularne i cikličke komponente u određenom razdoblju (I/C); ili MCD (eng. months for cyclical dominance) kao broj mjeseci u kojima uzastopno dominira ciklička komponenta. Detaljnije vidjeti u: Ahec-Šonje (1995a).

TEST UZROČNOSTI - NADOPUNA "SCORING" METODE

Na temelju iznesenih poželjnih svojstava navješćujućih indikatora i izvedenih kriterija za njihovu ocjenu moguće je procijeniti izgleda za uspjeh istraživanja u hrvatskom gospodarstvu. S obzirom na uvjete u kojima je metoda nastajala nije neobično što se osnovni kriteriji s vremenom nisu bitno mijenjali. Međutim, NBER-ov obrazac ocjenjivanja nije pravilo, već samo okvir od kojem se prema potrebi može odstupiti ili ga se može nadopuniti provjerenim analitičkim metodama.

Suočen sa problemima statističke podloge domaći je istraživački tim bio prisiljen izvršiti neophodne izmjene "scoring" plana. Zbog kratkog vremenskog obuhvata serija, koje se prate tek od siječnja 1991. nije bilo moguće utvrditi pravilnosti u njihovom obrazcu ponašanja, niti odrediti datume zaokreta referentne serije. I što je najvažnije, to je onemogućilo primjenu značajnih kriterija "scoring" sustava: usklađenost kretanja indikatora i referentne serije, te vremensku konzistentnost indikatora u prethodenju, praćenju ili zaostajanju¹⁵.

Da bi se istraživanje ipak temeljilo na konzistentnom metodološkom postupku ova se dva kriterija zamjenjuju **Grangerovim testom uzročnosti**. Premda NBER ne provodi testiranje uzročnosti u potrazi za prethodećim pokazateljima, neki autori primijenjuju taj test za naknadnu provjeru prognostičke vrijednosti složenih indeksa (Auerbach, 1982).

Grangerova analiza uzročnosti¹⁶ dobiva značajan ponder u postupku ocjenjivanja i izboru navješćujućih indikatora hrvatskog gospodarstva.

¹⁵ *Prisjetimo se da je ova dva kriterija moguće primijeniti samo u slučaju dugogodišnjeg statističkog praćenja.*

¹⁶ *Od definicija uzročnosti u ekonometriji se najčešće upotrebljava Grangerova definicija (Charemza i Deadman, 1992): X je Granger uzročnik Y-a ako se tekuća vrijednost varijable Y može predvidjeti korištenjem prošlih vrijednosti varijable X, uz ostale nepromjenjene uvjete. Nadalje, X je trenutni uzročnik Y-a ako se tekuća vrijednost varijable Y može precizno predvidjeti korištenjem prošlih i tekuće vrijednosti varijable X.*

Ukratko, uz pretpostavku stacionarnosti vremenskih serija X_t i Y_t , testiranje Granger uzročnosti počinje od općeg, neograničenog VAR modela¹⁷ i sljedeće proširene specifikacije varijable Y , odnosno, u našem slučaju referentne serije (Charemza i Deadman, 1992):

$$y_t = A_0 D_t + \sum_{j=1}^k \alpha_j y_{t-j} + \sum_{j=1}^k \beta_j x_{t-j} + \varepsilon_j \quad (1)$$

gdje je $A_0 D_t$ deterministički dio jednadžbe (konstantni član), $\sum \alpha_j y_{t-j}$ je autoregresijska specifikacija varijable Y (referentne serije) na vlastite "lagirane" vrijednosti, te $\sum \beta_j x_{t-j}$ regresija referentne serije Y na "lagirane" vrijednosti varijable X , odnosno potencijalnog navješćujućeg pokazatelja. Ako su svi parametri β_j ($j = 1, \dots, k$) jednaki nula, varijabla X nije Granger uzročnik varijable Y . Testiranje se obavlja pomoću sljedećeg F-testa (Auerbach, 1982; Charemza i Deadman, 1992):

$$F = ((SSR_0 - SSR)/m) / (SSR/(T-k)) \quad (2)$$

gdje su: SSR_0 i SSR neobjašnjene sume kvadrata odstupanja ograničenog i neograničenog (općeg) modela¹⁸; m je broj linearnih ograničenja u linearnom regresijskom modelu (npr. $\beta_1 = \dots = \beta_k = 0$), T je ukupan broj opservacija, k je broj svih ocjenjenih parametara u općem (nerestriktivnom) modelu.

Dobivena statistička vrijednost za testiranje nul hipoteze ($\beta_1 = \dots = \beta_k = 0$) ima F distribuciju sa $(m, T-k)$ stupnjeva slobode i uspoređuje se sa

¹⁷ Opći VAR model - nerestriktivni vektorski autoregresijski model koji se svodi na regresiranje tekuće vrijednosti zavisne varijable na ostale varijable u modelu, odnosno njihove prošle (lagirane) vrijednosti s određenim vremenskim pomakom.

¹⁸ Opći ili neograničeni model obično se izražava u formi autoregresivnih distribuiranih pomaka (ADL-autoregressive distributed lag form). Zavisna varijabla Y funkcija je vlastitih prošlih vrijednosti, te sadašnje i prošlih vrijednosti nezavisne varijable X . Ograničena ili restriktivna regresijska jednadžba je specijalni slučaj opće regresijske jednadžbe uz neka ograničenja (Charemza i Deadman, 1992).

tabličnom vrijednosti uz određenu razinu signifikantnosti. Ukoliko na temelju izračunate F statistike odbacimo nul hipotezu, uz prihvatljivu razinu signifikantnosti možemo identificirati seriju - Granger uzročnika referentne serije.

Upotrebom testa uzročnosti izvršena je značajna prilagodba izvorne metodologije domaćim ekonomskim uvjetima. Riječ je o izvjesnoj metodološkoj "inovaciji", s obzirom da u primjeni pristupa indikatora dosad nije zabilježeno korištenje ove pomoćne metode (osim u spomenutom slučaju ex-post provjere prognostičke vrijednosti indikatora). Pomoću tog testa otkrivaju se potencijalni navješćujući indikatori hrvatskog gospodarstva, utvrđuje se vrijeme njihova prethođenja i ocjenjuje jakost veze između referentne serije i navješćujućeg indikatora¹⁹.

IZRAČUNAVANJE SLOŽENOG (KOMPOZITNOG) INDEKSA

Prve složene indekse izračunali su Geoffrey H. Moore i Julius Shiskin još 1958. godine. **Složeni ili kompozitni indeks** je mjera koja ukazuje na promjenu smjera kretanja izabranog ekonomskog agregata i mjeri "prosječno" ponašanje grupe vremenskih serija koje predočavaju najrazličitije ekonomske procese (Niemira i Klein, 1994; Zarnowitz i Boschan, 1975; U.S. Department of Commerce, 1977). Ovisno o klasifikaciji serija razlikujemo **složene indekse navješćujućih, pratećih ili zaostajućih indikatora**.

Zbog svog širokog i raznolikog obuhvata složeni indeks je pouzdaniji ciklički indikator i manje je podložan iregularnim kretanjima za razliku od svojih pojedinih komponenti. "Scoring" sustav se unaprijed "pobrinuo" da u složeni indeks uđu samo najbolje serije koje zadovoljavaju odgovarajući obrazac ponašanja: te su serije "izgladene",

¹⁹ *Zainteresiranog čitatelja upućujem na spomenuti magistarski rad (Ahec-Šonje, 1995a) u kojem je detaljno prikazano ocjenjivanje serija prema rezultatima Granger testa uzročnosti.*

objavljaju se mjesečno s vrlo malim zaostatkom, nisu podložne čestim revizijama, odražavaju različite ekonomske aktivnosti. Ukratko, radi se o nekolicini (najčešće 10-12) ekonomskih pokazatelja s najvišim "scoring" ocjenama.

NBER/BEA metoda izračunavanja složenog indeksa već se godinama usavršava uzimajući u obzir doprinose u teoriji, premda većim dijelom ovisi o napretku statističkih i matematičkih metoda i programskoj podršci. Potraga za domaćim prognostičkim iskazom temelji se na najnovijim metodološkim pomacima, koji su učinjeni posljednjom revizijom metode 1993. godine (Niemira i Klein, 1994). Uvažavajući nova metodološka pravila, slijedi kraći prikaz osnovnih koraka izrade složenog indeksa navješćujućih indikatora²⁰.

1) Izračunavanje simetričnih (Shiskinovih) postotnih promjena

Shiskin (1961) upozorava na problem korištenja tradicionalne jednadžbe za računanje stopa rasta $((X_t - X_{t-1})/X_{t-1} * 100)$, koja unosi zabunu u interpretaciju rezultata. Primjerice, uz originalne mjesečne vrijednosti neke serije od: 40, 80, 40, 80, 40, upotreba tradicionalne jednadžbe daje sljedeće stope: +100%, -50%, +100%, -50%, s aritmetičkom sredinom stopa rasta od +25%. Međutim, teško je razumijeti kakav to pozitivan prosječan rast pokazuje serija s navedenim originalnim vrijednostima. Stoga Shiskin predlaže upotrebu jednadžbe, koja će u navedenom primjeru iskazati očekivanu prosječnu stopu rasta od 0%, čime osigurava simetričnost pozitivnih i negativnih promjena, a ta jednadžba glasi²¹:

$$c_{it} = 200(X_{it} - X_{it-1}) / (X_{it} + X_{it-1}) \quad (1)$$

²⁰ Premda se postupak izračunavanja koristi za sve grupe pokazatelja (prateće, zaostajuće i navješćujuće), u daljnjem tekstu se zbog jednostavnosti govori samo o složenom indeksu navješćujućih pokazatelja.

²¹ Uz pomoć izraza za lučnu elastičnost Shiskin dolazi do izraza koji uzima u obzir simetričnost pozitivnih i negativnih postotnih promjena (Gapinski, 1982): $100(X_t - X_{t-1}) / ((X_t + X_{t-1}) / 2)$.

gdje je X_i vrijednost navješćujućeg indikatora i u razdobljima t i $t-1$, a c_i su njegove **simetrične mjesečne postotne promjene** ($i = 1, 2, 3, \dots, k$, gdje je k ukupan broj serija koje ulaze u složeni indeks; $t = 2, 3, 4, \dots, n$)²².

2) Standardizacija amplitude

Za svaki navješćujući indikator računa se tzv. standardizacijski faktor (srednja apsolutna postotna promjena) na sljedeći način:

$$A_i = \sum_{t=2}^n |c_{it}| / (N-1) \quad (2)$$

gdje je N ukupan broj mjesečnih opservacija. Nakon što se izračuna standardizacijski faktor A_i za svaku komponentu složenog indeksa, slijedi standardizacija simetričnih mjesečnih postotnih promjena (amplitude) svake komponente i :

$$s_{it} = c_{it} / A_i \quad (3)$$

gdje je A_i fiksni standardizacijski faktor u promatranom razdoblju. Ovim korakom nastoji se spriječiti dominantan utjecaj pojedinačnih pokazatelja u kretanju složenog indeksa.

3) Ponderiranje standardiziranih promjena

Na temelju "scoring" ocjena najboljih navješćujućih indikatora izračunavaju se njihovi ponderi značajnosti, koji odražavaju ponašanje tih serija u odnosu na referentnu seriju:

²² Ako je navješćujući indikator već izražen u stopama rasta ili sadrži negativne vrijednosti i nule, tada se primijenjuje jednostavna metoda izračunavanja prvih diferencija: $c_{it} = X_{it} - X_{it-1}$.

$$W_i = S_i / (\sum_{i=1}^k S_i / k) \quad (4)$$

Ponder je odnos "scoring" ocjene pojedinačnog indikatora (S_i) i prosječne ocjene svih indikatora (k = broj komponenti složenog indeksa). Ponderi služe za "uprosječivanje" standardiziranih mjesečnih postotnih promjena pojedinih indikatora s_{it} :

$$R_t = (\sum_{i=1}^k s_{it} W_i) / (\sum_{i=1}^k W_i) \quad (5)$$

4) Standardizacija R_t

Prije nego što se dobivena serija R_t (koja odražava uprosječeno kretanje izdvojenih navješćujućih indikatora) pretvori u bazne indekse, NBER predlaže standardizaciju te serije²³. Pri tom se **standardizacijski faktor skupine** navješćujućih indikatora (F) izračunava prema jednadžbi:

$$F = ((\sum_{t=2}^n |R_t|) / (N-1)) / ((\sum_{t=2}^n |P_t|) / (N-1)) \quad (6)$$

gdje je P_t dobivena istim postupkom kao i serija R_t , samo na temelju grupe pratećih pokazatelja. Standardizacijom se serija R_t prilagođava prosječnoj promjeni indeksa pratećih pokazatelja:

$$r_t = R_t / F \quad (7)$$

gdje r_t predstavlja prilagođene ponderirane mjesečne promjene skupine navješćujućih indikatora.

²³ Ovisno o cilju istraživanja serija R_t može se izračunati na temelju bilo koje grupe indikatora, dakle, za skupinu navješćujućih, pratećih i zaostajućih serija.

Ovaj se korak može preskočiti ukoliko se ne analizira kretanje pratećih pokazatelja, koji su zapravo zamjena za referentnu seriju. Stoga je nakon izračunavanja serije R_t moguće odmah prijeći na korak 5.

5) Pretvaranje mjesečnih promjena u indeks

Seriju (ne)standardiziranih prosječnih promjena izražavamo u obliku indeksa primjenom sljedećeg izraza²⁴:

$$I_t = I_{t-1}((200 + r_t)/(200 - r_t)) \quad (8)$$

gdje se za početnu vrijednost indeksa uobičajeno stavlja indeks 100. Ovaj postupak "vraća" simetrične postotne promjene u konvencionalni oblik promjena. **Prognostički iskaz - složeni indeks navješćujućih pokazatelja** I_t moguće je preračunati na bilo koju drugu bazu, dijeljenjem svake mjesečne vrijednosti indeksa (I_t) s indeksom novog baznog razdoblja.

Dobiveni se pokazatelj može promatrati kao "vagana" sredina pojedinačnih navješćujućih pokazatelja, što samo potvrđuje suštinsku jednostavnost prikazane metodologije. Premda odražava amplitudu i smjer promjena svake njegove komponente, složeni indeks ipak "izgladuje" njihove slučajne oscilacije. Stoga se njegovim korištenjem u prognostičke svrhe smanjuje mogućnost davanja krivih prognoza upotrebom samo jednog navješćujućeg pokazatelja.

²⁴ Pomoću istog izraza za lučnu elastičnost "vraćaju" se (ne)standardizirane mjesečne stope promjene u oblik indeksa (Gapinski, 1982):

$$r_t = 100(I_t - I_{t-1}) / ((I_t + I_{t-1}) / 2), \text{ od kuda slijedi:}$$

$$I_t = I_{t-1}(200 + r_t / 200 - r_t).$$

3. CROLEI indeks gospodarskih predviđanja

U gotovo dvije godine istraživačkog rada domaći istraživački tim pokušao je ovladati tehnikama ovog jednostavnog prognostičkog pristupa. Dugoročni cilj njegovog uvođenja je podizanje kvalitete analitičkih i prognostičkih osnovica za vođenje tekuće ekonomske politike. Primjena ove metode pomaže u razumijevanju i lakšem uočavanju brojnih skrivenih ekonomskih veza, koje postoje unutar hrvatskog gospodarstva.

U dosadašnjem istraživačkom radu stvorena je statistička podloga koja obuhvaća gotovo 150 različitih vremenskih serija. To je omogućilo primjenu već osmišljenih tehnika i metoda analize, premda su uočeni brojni nedostaci s obzirom na kvalitetu i statistički obuhvat podataka. Stoga se u svrhu davanja kvalitetnijih prognostičkih iskaza posebno treba posvetiti sređivanju domaće statističke podloge. Taj dio istraživačkog rada sugerira koja bi statistička praćenja bilo poželjno dalje usavršavati, odnosno da li treba pokrenuti neka nova praćenja.

Premda je bio problem čime će se mjeriti ekonomsko stanje u Hrvatskoj, pronađeno je relativno zadovoljavajuće rješenje. Oslonivši se na tuđa istraživačka iskustva izbor je pao na indeks industrijske proizvodnje. Iako industrijska proizvodnja kao referentna serija zaobilazi značajan dio ekonomske aktivnosti, njezino korištenje nije bitno umanjilo vrijednost prognostičkog iskaza. No, već buduće istraživačke napore treba usmjeriti na pronalaženje referentne serije šireg ekonomskog obuhvata.

S obzirom da bi nas strogo pridržavanje svih propisanih koraka NBER metode zaustavilo na samom početku istraživanja, izračunavanje CROLEI indeksa samo se oslanjalo na izvorne metodološke preporuke. Najveći su problemi pri tom bili kratkoća vremenskih serija, problematično "ponašanje" izabrane referentne serije u promatranom razdoblju i nedovoljno razrađena statistička podloga. Stoga je bilo potrebno izvršiti manje izmjene i prilagodbu metode domaćim ekonomskim uvjetima.

Ocjenjivanje potencijalnih navješćujućih indikatora za izradu CROLEI indeksa provodi se nad realnim i desezoniranim podacima uz nešto izmijenjene "scoring" kriterije:

- 1) ekonomska značajnost (signifikantnost) serije,
- 2) statistička pouzdanost serije,
- 3) konzistentnost u prethođenju koja se testira Granger testom uzročnosti,
- 4) izglađenost serije,
- 5) ažurnost statističke podloge.

Ocjenjivati se mogu sve serije iz raspoložive baze podataka, premda se postupak može značajno skratiti eliminiranjem serija koje ne zadovoljavaju određeni obrazac ponašanja. To znači da se grafičkom usporedbom kretanja industrije sa kretanjem svih raspoloživih serija i primjenom Granger testa uzročnosti uklanjaju sve serije koje nisu čak niti potencijalni navješćujući indikatori.

Prilikom ocjenjivanja uvažena je činjenica da NBER-ov obrazac pruža značajnu slobodu istraživačima prilikom izbora raspona ocjena i davanja pondera značajnosti pojedinim "scoring" kriterijima²⁵. **Vremenske serije s dovoljno dugim vremenom prethođenja i najvećim ukupnim "scoring" ocjenama čine listu izdvojenih navješćujućih indikatora hrvatskog gospodarstva.** Danas su to sljedeće serije koje pokrivaju najznačajnije ekonomske procese:

- 1) indeks fizičkog obujma zaliha sirovina kod proizvođača u industriji (S11),
- 2) broj korisnika novčane naknade zbog nezaposlenosti (S28),
- 3) izvršeni sati rada u graditeljstvu (S31),
- 4) vrijednost ugovorenih građevinskih radova u zemlji, ukupno (S97),
- 5) promet u trgovini na malo (S36),
- 6) promet u trgovini na veliko (S37),
- 7) uvoz repromaterijala (S55),
- 8) materijalni rashodi neprivrede (S61),
- 9) primanja stanovništva od prodaje proizvoda i usluga (S67),
- 10) Novčana masa, M1, (S76).

²⁵ Detaljnije vidjeti u *Ahec-Šonje (1995a)*.

U slijedećoj tablici prikazuju se konačni rezultati ocjenjivanja navedenih komponenti CROLEI indeksa:

Tablica 1.
REZULTATI OCJENJIVANJA CROLEI KOMPONENTI

BROJ SERIJE	Prosječno vrijeme prethođenja (broj mjeseci)	REZULTATI OCJENE SERIJA						UKUPNO (Si)	PONDER (Wi)
		Ekonomska značajnost 20%	Statistička pouzdanost 10%	Izgladenost 20%	Ažurnost 10%	Konzistentnost G-test 40%			
S11	-8	80	100	60	60	50	64	0,859	
S28	-7.5	80	80	100	100	70	82	1,101	
S31	-11	80	100	80	60	70	76	1,020	
S97	-7.2	80	100	80	60	50	68	0,913	
S36	-4.5	80	90	100	100	80	87	1,168	
S37	-10.5	80	90	60	100	80	79	1,060	
S55	-4.8	80	60	0	60	80	60	0,805	
S61	-4.5	100	90	60	100	80	73	0,980	
S67	-8.5	80	100	60	100	80	80	1,074	
S76	-8	100	80	100	100	70	76	1,020	
UKUPNO							745	10,0	

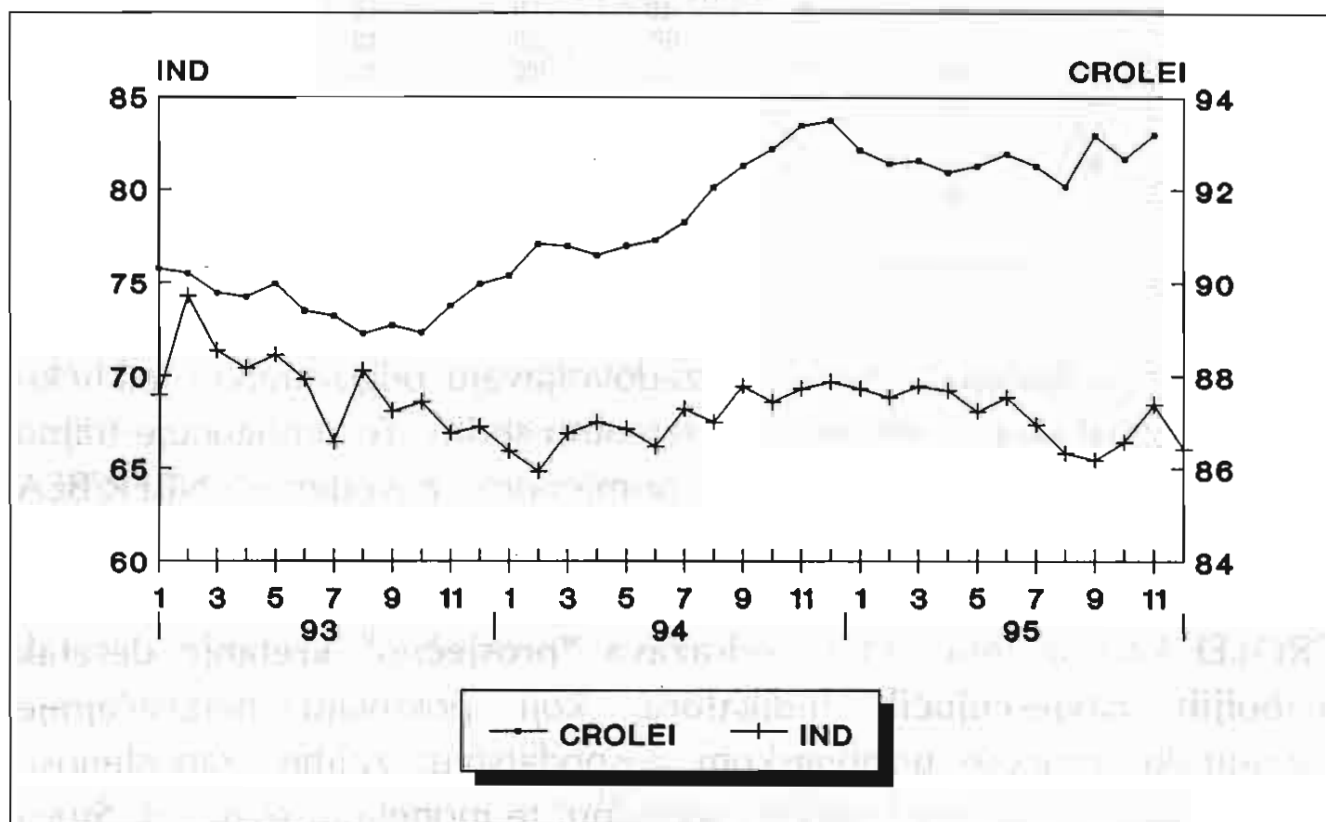
Navedeni navješćujući indikatori zadovoljavaju odgovarajući (ciklički) obrazac ponašanja u odnosu na referentnu seriju. To omogućuje trajno izračunavanje CROLEI indeksa primjenom navedenih NBER/BEA metodoloških koraka, i to bez značajnijih izmjena²⁶.

CROLEI kao složeni indeks **odražava "prosječno" kretanje desetak najboljih navješćujućih indikatora**, koji pokrivaju najznačajnije ekonomske procese u hrvatskom gospodarstvu: zalihe, zaposlenost, graditeljstvo, unutarnju i vanjsku trgovinu, te monetarni segment. Stoga bi ova jedinstvena mjera gospodarskih predviđanja trebala biti manje podložna iregularnim kretanjima, budući da "uprosječuje" kretanje svih svojih komponenti. Prognoze koje se temelje na složenom indeksu

²⁶ U našem slučaju preskače se postupak standardizacije "ponderiranog" prosjeka navješćujućih pokazatelja R_i (korak 4), budući da u ovoj fazi istraživanja ne otkrivamo prateće pokazatelje industrijske proizvodnje.

trebaju biti vrlo oprezne i općenite²⁷. Uvažavajući NBER/BEA preporuke o maksimalnom oprezu pri tumačenju indeksa, može se reći da **CROLEI prognostički iskaz navješćuje dinamiku industrijske proizvodnje i globalne ekonomske aktivnosti oko 5-6 mjeseci unaprijed**, uz manja odstupanja. To potvrđuje ex-post analiza njegovog kretanja u protekle dvije godine, što se jasno vidi iz sljedeće slike:

Slika 1.
CROLEI I INDUSTRIJSKA PROIZVODNJA
(1/93- 11/95)



²⁷ Najčešće se može čuti mišljenje da složeni indeks prognozira kretanje referentne serije onoliko mjeseci unaprijed, koliko iznosi ponderirana sredina vremena prethođenja svih njegovih komponenti (Zarnowitz i Boschan, 1975). Činjenica je, ipak, da naoko jednostavno tumačenje indeksa često prerasta u složen empirijski izazov, koji i danas donosi istraživačima brojne probleme. Međutim, autori koji su testirali prognostičku vrijednost složenih indeksa, zaključili su da BEA/US DOC indeks pruža bolju najavu od suprotstavljene ekonometrijske prognoze (Auerbach, 1982).

CROLEI indeks dostiže najnižu razinu u kolovozu 1993. godine kada se dotadašnje negativne stope zamjenjuju blagim, ali ipak očiglednim pozitivnim stopama rasta. S obzirom da industrijska proizvodnja zaokreće tek u veljači 1994. godine, CROLEI indeks najavio je njezin "ciklički" oporavak čak 6 mjeseci unaprijed. Slično je i s kretanjem CROLEI pokazatelja u 1995. godini. Blago uzastopno mjesečno opadanje prognostičkog indeksa u prosincu 1994. i u prvom tromjesječju 1995. godine, navijestilo je stagnaciju i opadanje referentne serije sredinom prošle godine, ali i postupno zaustavljanje negativnih tendencija krajem 1995. godine. Ponašanje CROLEI pokazatelja u svibnju, lipnju i srpnju 1995. ukazuje na mogućnost blagog pada industrijske proizvodnje na samom početku 1996. godine. Istraživačko iskustvo govori da se ne radi o neočekivanom i iznanađujućem kretanju. Blaga ciklička stagnacija (opadanje vrijednosti) industrijske proizvodnje predstavlja gotovo uobičajeno kretanje ove serije početkom godine.

Značajno je naglasiti da zbog svoje metodološke pozadine, **CROLEI, kao i svaki složeni indeks navješćujućih indikatora navješćuje promjene smjera kretanja ekonomske aktivnosti i značajnije cikličke zaokrete, a ne povremene (slučajne) mjesečne oscilacije.** Stoga s oprezom treba promatrati iznenadni "oporavak" industrije u posljednjem kvartalu 1995. godine, naročito zbog vrijednosti referentne serije u prosincu te iste godine.

Za sada je teško dati sigurnu prognozu za cijelu 1996. godinu, s obzirom da (u vrijeme pisanja ovog članka) raspolažemo s vrijednostima navješćujućeg indeksa do studenog 1995. godine. Njegova posljednja kretanja uzlaznog trenda u razdoblju rujan -studen prošle godine, sugeriraju mogućnost značajnijeg "oporavka" industrije krajem prvog tromjesječja 1996. Ukoliko se taj trend rasta vrijednosti CROLEI indeksa nastavi i u prosincu 1995. moguće je s većom sigurnošću najaviti porast industrijske proizvodnje i globalne ekonomske aktivnosti od ožujka 1996. nadalje.

Zaključak

Dosadašnji istraživački naponi u potpunosti su opravdali razvoj "barometarskog" predviđanja ekonomskih fluktuacija, sugerirajući korištenje ove metode u kombinaciji s drugim prognostičkim metodama. Koristi koje donosi pristup indikatora potvrdile su se u praksi mnogih, uglavnom razvijenih zemalja. Većina njih već godinama objavljuje navješćujuće (prateće i zaostajuće) ekonomske indikatore u stručnim i specijaliziranim publikacijama, ali i u popularnim ekonomskim časopisima i dnevnom tisku.

Značajno je naglasiti činjenicu da odnedavno i Hrvatska ima vlastiti "barometarski" prognostički iskaz - indeks industrijskog (ekonomskog) predviđanja. Jednostavnost analitičkih temelja ove metode omogućila je primjenu sustava navješćujućih indikatora i u bitno drugačijem ekonomskom okruženju od onog u kojem se metoda razvijala. Usprkos problemima statističke prirode empirijski su rezultati opravdali primjenu ove sofisticirane metode u domaćim ekonomskim uvjetima. CROLEI indeks nosi slične ili gotovo iste informacije kao i svaki takav pokazatelj konstruiran u razvijenim tržišnim ekonomijama. Svojim je kretanjem u ovih kratkih pet godina CROLEI opravdao svoju osnovnu prognostičku zadaću, najavljujući "cikličke" zaokrete industrijske proizvodnje i globalne ekonomske aktivnosti.

Nadgradnja i usavršavanje ove metode ovisit će o brzini i efikasnosti kojom će hrvatsko gospodarstvo usvajati tržišne kriterije poslovanja. Stoga bi sa sazrijevanjem tržišne ekonomije kod nas trebalo rasti i zanimanje ekonomske javnosti za tržišne signale i nagovještaje kojima se budućnost nastoji učiniti "sigurnom". Pri tom bi kreatori tekuće ekonomske politike, velika poduzeća i sitni poduzetnici bili najznačajniji korisnici takvih informacija. To bi opravdalo osnovni istraživački cilj, da se u budućnosti ovaj pristup razvije u alternativni analitički sustav za praćenje, nadgledanje i navješćivanje fluktuacija u hrvatskom gospodarstvu.

LITERATURA

Ahec-Šonje, Amina (1995a): **Sustav prethodećih pokazatelja gospodarske aktivnosti u Republici Hrvatskoj**, Magistarski rad, Zagreb.

Ahec-Šonje, Amina (1995b): "Metode predviđanja ekonomskih fluktuacija s naglaskom na pristup indikatora", **Ekonomski pregled**, 11-12, u tisku.

Ahec-Šonje, A., Anušić, Z., Drinovac, I., i Ž. Miljenović (1994): **Metodološki okvir za izradu sustava prethodećih ekonomskih pokazatelja**, Prilog 2 (projektna dokumentacija), EIZ, Zagreb.

Auerbach, Alan J. (1982): "The Index of Leading Indicators: 'Measurement Without Theory', Thirty-five Years Later", **The Review of Economics and Statistics**, 64: str. 589-595.

Charemza, Wojciech W. i Derek F. Deadman (1992): **New Directions in Econometric Practice: General to Specific Modelling, Cointegration and Vector Autoregression**, Edward Elgar, Aldershot.

Gapinski, James H. (1982): **Macroeconomic Theory: Statics, Dynamics, and Policy**, McGraw-Hill, New York.

Granger, C.W.J., (1989): **Forecasting in Business and Economics**, Academic Press, London. (drugo izdanje).

Koopmans, Tjalling C. (1947): "Measurement Without Theory", **The Review of Economics and Statistics**, 29: str. 161-172.

Lahiri, Kajal i Geoffrey H. Moore (1991): **Leading Economic Indicators: New Approaches and Forecasting Records**, Cambridge University Press, Cambridge.

Moore, Geoffrey H. i Julius Shiskin (1967): **Indicators of Business Expansions and Contractions**, National Bureau of Economic Research, New York.

Neftci, Salih N. (1979): "Lead-Lag Relations, Exogeneity and Prediction of Economic Time Series", **Econometrica**, 47: str. 101-113.

Niemira, Michael P. i Philip A. Klein (1994): **Forecasting Financial and Economic Cycles**, Wiley & Sons, New York.

OECD Department of Economics and Statistics (1987): **OECD Leading Indicators and Business Cycles in Member Countries 1960-1985**, Sources and Methods, broj 39, OECD, Paris.

Shiskin, Julius (1961): **Signals of Recession and Recovery: An Experiment with Monthly Reporting**, NBER, New York.

U.S. Department of Commerce, Bureau of Economic Analysis, (1977): **Handbook of Cyclical Indicators**.

Zarnowitz, Victor (1992): **Business Cycles: Theory, History, Indicators, and Forecasting**, The University of Chicago Press, za NBER, Chicago.

Zarnowitz, Victor i Charlotte Boschan (1975): "Cyclical Indicators: An Evaluation and New Leading Indexes" u U.S. Department of Commerce, Bureau of Economic Analysis (1977): **Handbook of Cyclical Indicators**.