

Amina Ahec-Šonje*

UDK 338.97:311.17(497.5)

Izvorni znanstveni rad

EKONOMSKA PROGNOSTIKA U HRVATSKOJ: CROLEI INDEKS

Autorica naglašava zbog čega je metoda indikatora jednostavna i popularna tehnika analize i prognoziranja ekonomskih fluktuacija, navodeći razloge i uzroke učinjenih intervencija prilikom posljednje revizije metode na svršetku godine 1999. Uspoređujući ponašanje prognostičkog indeksa prije i poslije provedene revizije, autorica iznosi brojne analitičke i prognostičke prednosti novog, revidiranog indeksa pred dosadašnjim.

Uvod

CROLEI¹ indeks prognostički je pokazatelj, čija je svrha objašnjavanje i predviđanje fluktuacija u hrvatskome gospodarstvu. Njega je moguće izračunati samo uz kvalitetno pripremljen skup navješćujućih indikatora, koji su uz osjetan vremenski pomak ciklički usuglašeni sa kretanjem ukupne gospodarske aktivnosti. To znači da navješćujućih indikatora zaokreću i po nekoliko mjeseci prije nego što dođe do stvarnog zaokreta u ekonomskoj aktivnosti.

U uvjetima kada u Hrvatskoj objektivno nije bilo moguće izgraditi domaći sofisticirani parametarski model za ekonomsku analizu i prognozu, ponajviše zbog prekratkih vremenskih serija koje su osnovica za razvitak takvih modela, počeli su se proučavati alternativni analitički pristupi. Jedan je od njih svakako pristup navješćujućih indikatora, u ekonomskim krugovima poznat i pod nazivom barometarska metoda predviđanja, razvijena na postavkama poznatih teorija o poslovnim ciklusima. Tako je prije šest godina započeo razvitak sustava indikatora u Hrvatskoj koji služi za izračun prognostičkog iskaza o ekonomskoj aktivnosti. Ono što je još važnije od same prognoze jest čitav niz pomoćnih metodoloških koraka i analiza, što sustav

* A. Ahec-Šonje, magistar znanosti, asistent u Ekonomskom institutu, Zagreb. Članak primljen u uredništvu: 23. 05. 2000.

¹ CROLEI je skraćeni izraz za složeni indeks navješćujućih indikatora (Croatian Leading Economic Indicator). Premda se indeks počeo razvijati još godine 1994., on se prvi put javno objavljuje tek na svršetku godine 1995. u okviru Mjesečnog statističkog prikaza Ministarstva financija RH, koje sve do danas redovito izvještava o kretanju tog prognostičkoga iskaza.

indikatora pretvara u izvor korisnih informacija o "skrivenim" vezama u gospodarstvu. Stoga nije neobično što je ta metoda veoma popularna u razvijenim tržišnim gospodarstvima, gdje se gotovo svi ekonomski subjekti koriste njezinim rezultatima kao stručnim osloncem pri donošenju poslovnih odluka.

Hrvatski prognostički indeks metodološki se oslanja na originalan pristup indikatora, koji je zasnovala poznata američka istraživačka institucija NBER. Budući da već postoji priličan broj domaćih stručnih radova koji su opisivali i izvornu metodu i postupak prilagodbe metode domaćim ekonomskim uvjetima, ovaj će rad izložiti posljednje istraživačke rezultate vezane uz učinjene metodološke intervencije. Ideja je da se u prvom dijelu ovoga rada analiziraju dosadašnja kretanja CROLEI indeksa i njegova prognostička snaga u proteklom razdoblju. Drugi dio rada razmatra uzroke intervencija u samu metodu indikatora i daje veoma kratak informativni prikaz posljednje revizije CROLEI indeksa provedene na svršetku godine 1999. radi poboljšanja prognostičke vrijednosti toga sustava. U posljednjem ćemo dijelu analizirati obilježja novog, revidiranog sustava indikatora te usporediti prognostičke vrijednosti novog i "starog" CROLEI indeksa.

Odnos prema ekonomskoj prognostici u Hrvatskoj - pogled unatrag

Kada je godine 1937. nastupila panika zbog nove oštre recesije, jer posljedice Velike depresije još nisu bile zaboravljene, tadašnji se američki ministar financija Henry Morgenthau, Jr. obratio istraživačima NBER-a (National Bureau of Economic Research) s molbom da izgrade sustav indikatora koji bi signalizirali poremećaje u ekonomiji. Od tada, pa sve do današnjih dana, SAD, ali uz njih i brojne druge zemlje (sve članice OECD-a, zemlje Istočne Azije), istražuju i objavljuju cikličke indikatore kojima se kao izvorom informacija o "zdravlju" gospodarstva koriste gotovo svi ekonomski subjekti. Kratkoročno prognoziranje sustavom indikatora privlači veliku pažnju u razvijenim tržišnim ekonomijama zbog njihovog "gorkog" iskustva vezanog uz poslovne cikluse. U mnogim zemljama već duže vrijeme to istraživanje ima status državnog projekta koji trajno financira i potiče državna administracija svjesna potrebe kontinuiranog praćenja svih signala sa tržišta.

Kod nas je tek prije šest godina stvoren i promoviran prvi domaći sustav signalnih indikatora, i to slijedom tek pojedinačnog znanstvenog entuzijazma, a ne slijedom osvještene spoznaje potencijalnih korisnika o prednostima i potrebi praćenja signalnih indikatora. Pritom se kod nas i dalje zanemaruje činjenica da stručne ekonomske informacije o budućim ekonomskim izgledima mogu povećati efikasnost cijelog ekonomskog sustava ili barem ublažiti intenzitet poremećaja na tržištu. Od same prognostike, pri razvitku sustava indikatora mnogo je značajnije i vrednije prikupljanje i ažuriranje svih dostupnih ekonomskih pokazatelja, kontinuiranom analizom kojih se stječe osjećaj postojanja određenih statističkih pravilnosti i skrivenih veza u gospodarstvu. Uprkos "hladnom" stavu domaće ekonomske javnosti prema ekonomskoj prognostici u nas, CROLEI sustav ipak se uspio održati i u određenoj mjeri afirmirati kao jedina makroekonomska prognostička tehnika u ovom trenutku, a u posljednje vrijeme CROLEI iskaz počele su

objavljivati i komentirati određene međunarodne financijske institucije koje prate i analiziraju stanje u Hrvatskoj.

U čemu je tajna ove jednostavne i popularne metode analize i prognoziranja fluktuacija? Kompozitni ili složeni indeks indikatora, koji mogu biti navješćujući, prateći ili zaostajući, jest pokazatelj promjene smjera kretanja ukupne gospodarske aktivnosti ili bilo koje druge izabrane referentne serije. Indeks zapravo mjeri "prosječno" ponašanje jedne grupe vremenskih serija koje zastupaju različite aktivnosti i sektore u ekonomiji². Njihovo se kretanje podudara sa zaokretima serije koja se promatra, ali s određenim vremenskim pomakom. Prve složene indekse izračunali su još davne godine 1958. Geoffrey H. Moore i Julius Shiskin. To je bio početak razvitka metode prognoziranja kombinacijom različitih cikličkih pokazatelja.

Kada je domaći istraživački tim započeo s izgradnjom sustava indikatora hrvatskoga gospodarstva, bio je potpuno neizvjestan ishod toga istraživanja zbog problema prekratkih vremenskih serija da bi se na njima mogla uočiti "statistička pravilnost" ili pak "cikličnost" u kretanju. Vodeći se uputama originalne NBER metodologije, počelo se s izgradnjom baze podataka koja je osnovica svim daljnim metodološkim koracima. Na jednom su mjestu okupljeni najrazličitiji ekonomski pokazatelji, a baza je podložna trajnoj reviziji, izmjenama i nadopunama.

Složeni indeks (u našem slučaju CROLEI) zapravo simulira ekonomsku aktivnost uz manji ili veći vremenski pomak, a to ovisi o prognostičkoj snazi njegovih komponenti, o izabranim navješćujućim indikatorima. *Da bi takav indeks simulirao ukupnu aktivnost u zemlji, u njegovom izračunavanju mora sudjelovati što više različitih serija iz različitih područja ekonomskog života koje zadovoljavaju ciklički obrazac ponašanja, i one istovremeno moraju imati najbolja prognostička obilježja.* Zbog svog širokog obuhvata složeni je indeks pouzdaniji ciklički indikator i manje je podložan iregularnim kretanjima, za razliku od svojih pojedinih komponenti. Metoda indikatora u svom izvornom obliku vodi računa o tome da u prognostički indeks uđu samo vrlo ažurne i lako dostupne serije s malim zaostatkom u objavljivanju i one koje nisu podložne čestim revizijama. To je pitanje kvalitete statistike općenito, što u slučaju Hrvatske predstavlja jedan od najvećih ograničavajućih elemenata od samih početaka primjene metode indikatora, ali i u svim drugim ozbiljnijim analitičkim pokušajima.

Donedavno korišten prognostički indeks CROLEI prestao se objavljivati u posljednja tri mjeseca godine 1999. zbog temeljitog preispitivanja statističke baze i revizije pojedinih metodoloških koraka. Prije prikaza rezultata najnovije revizije, napisat ćemo nekoliko riječi o obilježjima dosadašnjeg CROLEI indeksa.

Od prve revizije metode provedene godine 1997. sve do sredine godine 1998. "stari" je CROLEI indeks odražavao kretanje dvanaest navješćujućih indikatora³.

² Niemira i Klein (1994.); Zarnowitz i Boschan (1975.); BEA/US Department of Commerce (1977.); Moore i Shiskin (1967.).

³ Ahec-Šonje, A. (ur.) i grupa autora (1997.).

Ono što najviše može “potresti” sustav indikatora i sam prognostički iskaz jesu česte promjene u statističkoj podlozi. Na žalost, to je u Hrvatskoj općenito najveći problem i ograničenje za svako ozbiljnije ekonomsko istraživanje, što narušava kontinuitet takvih istraživanja. Zbog jednostavnog prestanka statističkog praćenja i objavljivanja dviju serija⁴ iz sustava indikatora stvorenog 1997., uslijedila je intervencija u samu metodu izračunavanja indeksa. Od polovice 1998. do posljednjih mjeseci godine 1999. prognostički je indeks odražavao kretanje ovih najboljih navješćujućih pokazatelja (u zagradaama je pripadajući “lead-time” u odnosu na referentnu seriju):

- (1) Realizirane potrebe za radnicima u mjesecu (5-7 mjeseci).
- (2) Korisnici novčane naknade zbog nezaposlenosti (5-7 mjeseci).
- (3) Primanja stanovništva ostvarena prodajom robe i usluga (5-7 mjeseci).
- (4) Broj noćenja turista - ukupno (8-11 mjeseci).
- (5) Promet u trgovini na malo (7-8 mjeseci).
- (6) Zalihe u trgovini na malo (8-9 mjeseci).
- (7) Nekonsolidirani prihodi državnog, županijskog i općinskog proračuna (9-11 mjeseci).
- (8) Masa neto plaća, ukupno (8-10 mjeseci).
- (9) Ukupna likvidna sredstva M4 (10 mjeseci).
- (10) Plasmani (10 mjeseci).

CROLEI indeks jednostavna je analitička mjera, jer predstavlja ponderirani prosjek gore navedenih pojedinačnih navješćujućih indikatora. Kod dosadašnjeg je indeksa vagana aritmetička sredina pojedinačnih vremena prethođenja iznosila 8,2 mjeseca. Preporuka je utemeljitelja ove metode da utvrđeni “lead time” indeksa bude potreban uvjet za pravilnu analizu prognostičke vrijednosti indeksa. Dovoljan je uvjet izbor pravila prema kojem se ocjenjuje značenje promjena vrijednosti tog indeksa. Pritom naglašavamo da danas, nakon gotovo 70 godina postojanja te metode, ne postoji jedinstveni kriterij za određivanje vremena prethođenja složenog indeksa. U ekonomskoj literaturi postoji poduži popis takvih rješenja (Stekler, 1991.; Zarnowitz, 1992.; Dyckman i Stekler, 1966.). Kombinacijom spomenuta dva uvjeta NBER nudi jednostavno i razumljivo pravilo tumačenja prognostičkog indeksa koje kaže: tri uzastopna mjesečna pada (porasta) vrijednosti indeksa signaliziraju istosmjerni zaokret u referentnoj seriji, do kojeg bi moralo doći za onaj broj mjeseci koliko iznosi prosječni “lead-time” prognostičkog indeksa.


Na slici 1. prikazani su “stari” CROLEI indeks (koji se podvrgava reviziji na svršetku godine 1999.) i indeks fizičkog obujma ukupne industrijske proizvodnje koja je ključna referentna serija, ponašanje koje se analizira i prognozira sustavom indikatora. Do manjih ili većih promjena u kretanju prognostičkog indeksa u

⁴ To su realna neto plaća po zaposlenom u neprivredi i broj radnika na gradilištima.

proteklih osam godina došlo je u siječnju godine 1993., u veljači 1995., u svibnju 1995., u kolovozu 1995., u veljači 1996. i u lipnju godine 1998. Kao što se zamjećuje na slici, indeks je uz manje oscilacije ipak kontinuirano rastao sve od kolovoza godine 1995. do lipnja godine 1998., kada "simulira" početak recesije u hrvatskome gospodarstvu. U prijašnjim godinama veoma je teško razlučiti stvarne zaokrete u kretanju same referentne serije. Od onih najočitijih spominjemo zaokret ekonomske aktivnosti u veljači godine 1994., koji je CROLEI indeks uspio najaviti već u siječnju godine 1993., dakle, čitavih godinu dana unaprijed. U kolovozu godine 1995. svojim je kontinuiranim rastom indeks najavio rast gospodarske aktivnosti koji počinje u ožujku godine 1996. Manju negativnu oscilaciju referentne serije u posljednja tri mjeseca godine 1996. CROLEI indeks je prepoznao u veljači godine 1996., dakle, oko šest mjeseci prije. U drugom polugodištu godine 1999., tih posljednjih mjeseci izračunavanja, "stari" CROLEI, već opterećen brojnim izmjenama u statistici, nije uspio prepoznati i najaviti skorašnji zaokret gospodarske aktivnosti prema gore.

Slika 1.

DOSADAŠNJI CROLEI⁹⁹ INDEKS I INDUSTRIJSKA PROIZVODNJA



Domaći prognostički iskaz sasvim sigurno ima određenu snagu u analizi i predviđanju kretanja referentne serije. Premda broj mjeseci prethođenja u navedenim oscilacijskim točkama varira u promatranom razdoblju od 4 do gotovo 12 mjeseci, njihovom se prognoziranju pristupalo s velikim oprezom. Strukturne promjene u gospodarstvu i metodološke promjene u statističkoj podlozi uzrokovale su ograničenja u primjeni metode indikatora koja je valjalo prevladati najnovijom revizijom, provedenom na svršetku godine 1999.

Najnovije intervencije u CROLEI sustavu indikatora

Kada je godine 1995. zasnovana metodologija izračunavanja CROLEI indeksa, istraživački je tim bio svjestan da će postojeća statistička ograničenja i brzina promjena u ekonomskom okruženju uvjetovati veoma česte intervencije u statističkoj podlozi i u metodološkim koracima. Čak i u stabilnim ekonomskim uvjetima preispitivanje metode i njezina revizija uobičajeni su, već standardiziran, dio metode navješćujućih indikatora, čime se sustav indikatora obično svake dvije godine "osvježava" novim i kvalitetnijim statističkim praćenjima.

Revizija je potrebna zbog dva razloga, od kojih je prvi statističke, a drugi ekonomske prirode. Sa svakom novom mjesečnom opservacijom vremenska serija postaje duža i time kvalitetnija za analizu. Periodično dolazi do izmjena metodologije praćenja pojedinih serija, do uvođenja novih i napuštanja postojećih serija, što se odražava i na samu CROLEI bazu podataka. U Hrvatskoj su te promjene načina statističke obrade podataka toliko česte da se dovodi u pitanje kontinuitet i smisao gotovo svih domaćih ekonomskih istraživačkih pokušaja. Slijedom te logike CROLEI indeks morao bi se revidirati nakon svake veće metodološke intervencije državne statistike nad podacima koje objavljuje, što bi gotovo paraliziralo njegovo izračunavanje i objavljivanje. Ekonomski razlozi vezani su uz tranzicijska obilježja našeg gospodarstva, koje je u posljednjih desetak godina bilo izloženo brojnim zakonskim i institucionalnim promjenama, a taj proces ni danas nije završen. Sve dok traje proces prilagođivanja domaćih ekonomskih uvjeta zakonitostima i uvjetima razvijenih tržišta, češće su i promjene intenziteta utjecaja i značaja pojedinih ekonomskih varijabli na ukupnu ekonomsku aktivnost.

CROLEI statistika

Potruga za navješćujućim indikatorima počinje izgradnjom statističke podloge sastavljene od ekonomskih serija, koje objavljuju službena statistika i druge institucije (ZAP, Ministarstvo financija, Zavod za zapošljavanje, HNB). Osnovni je zahtjev metode indikatora da serije koje ulaze u CROLEI bazu imaju isti i što duži vremenski obuhvat. Kvalitetne metodološke napomene i objašnjenja olakšavaju korištenje tih podataka i pružaju istraživačima kvalitetne informacije o promatranim serijama. Poželjno je raspolagati ekonomskim serijama kod kojih se postiže najveća moguća brzina u prikupljanju i objavljivanju i onima s jednostavnim metodološkim objašnjenjima.

Oko polovine godine 1994. kada je započeto preuzimanje metode indikatora, statistička je baza sadržavala 98 vremenskih serija, a pri prvoj je reviziji godine 1997. već obuhvaćala 150 serija. Danas CROLEI baza ima dvostruko više pokazatelja nego godine 1994., odnosno 184 vremenske serije. Od početka svoga nastanka, sve do ove posljednje revizije, statistička je baza bila podložna značajnim i čestim promjenama, stoga su značajni istraživački naponi usmjeravani na kontinuirano praćenje, revidiranje i popunjavanje baze novim statističkim praćenjima. Serije u

novoj, revidiranoj CROLEI bazi pokrivaju sva najznačajnija područja u gospodarstvu:

- (1) Industrijska proizvodnja (41 pokazatelj)
- (2) Zaposlenost i neto plaće (3 pokazatelja)
- (3) Nezaposlenost i zapošljavanje (8 pokazatelja)
- (4) Graditeljstvo i turizam (4 pokazatelja)
- (5) Trgovina (8 pokazatelja, prestanak praćenja na svršetku godine 1998.)
- (6) Prijevoz (8 pokazatelja, prestanak praćenja na svršetku godine 1998.)
- (7) Vanjska trgovina (28 pokazatelja)
- (8) Nefinancijske transakcije (10 pokazatelja)
- (9) Monetarna statistika (35 pokazatelja)
- (10) Fiskalni pokazatelji (29 pokazatelja)
- (11) Cijene (16 pokazatelja).

Nakon pripreme statističke podloge slijedi analiza i dekompozicija vremenskih serija. Budući da svaka ekonomska serija pokazuje određeni stupanj sezonalnosti i iregularnosti u svojem kretanju, potrebno je njihovom dekompozicijom odvojiti sezonsku komponentu od trend-ciklusa i iregularne komponente, a to tako da se zadrže osnovna svojstva originalne ekonomske serije. Desezoniranje vremenskih serija za potrebe "scoring" metode provodi se uz pomoć programa X11ARIMA2000 (Statistics Canada), koji pruža sve značajne informacije o kvaliteti originalnih podataka. Rezultati dekompozicije serija baze za potrebe posljednje revizije nalaze se u Statističkom dodatku na svršetku rada.

Industrijska proizvodnja - agregat koji navješćujemo

Budući da se radi o praćenju ukupnog "zdravlja" gospodarstva, prvo je potrebno raščistiti dilemu o izboru makroekonomskog agregata koji najbolje odražava stanje ekonomske aktivnosti u zemlji. Taj zadatak nije nimalo jednostavan. Premda bi najbolji izbor bio bruto domaći proizvod, ovaj se najširi ekonomski agregat u najvećem broju zemalja prati samo na godišnjoj ili u najboljem slučaju na kvartalnoj razini. Vodeći računa o tome da je riječ o kratkoročnoj metodi prognoziranja indikatorima koji navješćuju mjesečne oscilacije u gospodarstvu, istraživačima ne preostaje mnogo prostora niti kandidata za izbor referentne serije. Većina njih odlučuje se za mjesečne indekse industrijske proizvodnje. Taj se izbor pokazao opravdanim, jer se u mnogim tržišnim ekonomijama "ciklus" u industriji gotovo poklapa sa cikličkim obrascem ponašanja BDP-a. Domaći istraživački tim više je puta provjerio ovu tvrdnju, uspoređujući kretanje bruto domaćeg proizvoda i industrijske proizvodnje, otkrivši velike sličnosti u kretanju tih dviju serija. Stoga se CROLEI sustav od samog početka razvitka koristi serijom indeksa fizičkog obujma ukupne industrijske proizvodnje kao ključnom referentnom serijom.

Ocjena kvalitete vremenskih serija ("scoring")

Velik je posao procijeniti i analizirati svaku seriju iz baze podataka koja obuhvaća više od 150 pokazatelja. Tim se metodološkim korakom procjenjuje uloga i kvaliteta ekonomskih varijabli kao mogućih signalnih indikatora fluktuacija u ekonomiji. Cilj je utvrditi upotrebljivost serija u analitičke i prognostičke svrhe, što istovremeno olakšava interpretaciju tekućih vrijednosti tih serija.

Ocjenjuju se samo realne i prethodno desezonirane vremenske serije. Izvorni "scoring" kriteriji pomažu pri otkrivanju usklađenosti kretanja serija i referentne serije pri dolovima i vrhovima ciklusa, kako bi se odredilo koliko dosljedno potencijalni navješćujući indikator prethodi referentnoj seriji. Na žalost, i danas nakon gotovo šest godina razvitka te metode kod nas, vremenski obuhvat ekonomskih pokazatelja iz CROLEI baze još uvijek je kraći od deset godina, što je prekratko za primjenu originalnog kriterija prema kojem se utvrđuje konzistentnost kretanja u dolovima i vrhovima "ciklusa". Istraživački je tim stoga primijenio parametarski pristup - Granger test kauzalnosti kao jedini raspoloživi objektivni test usklađenosti kretanja indikatora i referentne serije. Prilagođeni "scoring" sustav ocjenjivanja domaćih pokazatelja polazi od kriterija: (1) ocjena ekonomskog značaja serije, (2) ocjena statističke pouzdanosti serije, (3) vjerodostojnost u prethođenju referentnoj seriji, (4) ocjena "izgladenosti" serije, (5) ocjena ažurnosti statističke podloge.

Zbog velikog je broja serija u bazi ocjenjivanje moguće skratiti izbacivanjem iz razmatranja onih serija koje ne pokazuju nikakvu usklađenost s kretanjem referentne serije. To se postiže grafičkom usporedbom kretanja industrijske proizvodnje i serija iz baze. U izvornoj NBER metodi indikatora grafička je analiza ključna tehnika za razvrstavanje serija u skupine pratećih, navješćujućih i zaostajućih pokazatelja. No, šest je godina još uvijek prekratak rok za oslanjanje na sve izvorne metodološke korake. Kako taj problem ne bi postao glavnim ograničenjem primjene ove popularne metode, domaći je istraživački tim upotrijebio Granger test uzročnosti kao dopunsku metodu za izbor najboljih navješćujućih indikatora, koji premošćuje problem vremenske ograničenosti domaće statističke podloge, ali ponajviše služi kao ključni metodološki alat za utvrđivanje "lead time" pojedinih serija. Stoga je tek nakon Granger testa uzročnosti⁵ moguće sa sigurnošću ukloniti iz razmatranja sve serije koje konzistentno ne prethode referentnoj seriji.

⁵ Testiranje serija započinje ekonometrijskom ocjenom autoregresijske specifikacije industrijske proizvodnje, koja se zatim uspoređuje sa proširenim modelom u kojem se kao neovisne varijable pojavljuju "lagirane" vrijednosti potencijalnih prethodećih pokazatelja. U testiranju Granger uzročnosti polazi se od ove proširene specifikacije industrijske proizvodnje:

$$IND_t = A_0 D_t + \sum_{j=1}^k \alpha_j IND_{t-j} + \sum_{j=1}^k \beta_j LI_{t-j} + \varepsilon_j$$

Gdje je $A_0 D_t$ deterministički dio jednadžbe (konstantni član), $\sum_{j=1}^k \alpha_j IND_{t-j}$ je autoregresijska specifikacija industrijske proizvodnje na vlastite "lagirane" vrijednosti i

Posljednja revizija CROLEI indeksa nije zadirala u osnovne navedene kriterije, već su učinjene sitne izmjene kod pojedinih dijelova potkriterija i pripadajućih ocjena, čime su se nastojali pooštriti kriteriji posebno kod ocjene učestalosti metodoloških promjena u statističkoj bazi⁶. Dodatak B na svršetku rada sadrži tablice koje pružaju primjer ocjenjivanja pojedine serije prema gore navedenim kriterijima.

“Scoring” rezultati - nove komponente CROLEI⁰⁰ indeksa

Od svake se revizije očekuju određena poboljšanja, jer je moguće ispraviti neke nepravilnosti koje su se pojavile u vremenu između dviju provedenih revizija. To se posebno odnosi na učestale promjene metode obuhvata statističkih podataka, čemu se istraživači moraju prilagoditi i na što ne mogu utjecati. Stoga se i očekuje da će svaka nova revizija rezultirati izborom još boljih i kvalitetnijih navješćujućih indikatora koji podižu prognostičku kvalitetu CROLEI indeksa.

Kombinacijom grafičke metode i testa kauzalnosti posljednjom je revizijom izdvojeno 27 potencijalnih najboljih navješćujućih varijabli koje navodimo u tablici 1.

Pri prvoj reviziji godine 1997. šira lista potencijalnih “leadera” sadržala je 37 vremenskih serija. Usporedbom lista iz godine 1999. i 1997. zamjećuje se da čak 10 pokazatelja i nakon najnovije revizije ima obilježja najboljih “leadera”. To samo potvrđuje ekonomsku značajnost ovih serija i njihovu visoku usklađenost ponašanja u odnosu na referentnu seriju, a to podiže vjerodostojnost ove prognostičke metode. Na široj listi indikatora i ovog puta su se našle serije s liste iz godine 1997. i to: novoprijavljeni radi zaposlenja u tijeku mjeseca; broj noćenja turista, ukupno; broj noćenja stranih turista; promet u trgovini na malo; nekonsolidirani prihodi državnog, županijskih i općinskih proračuna; masa neto plaća, ukupno; ukupna likvidna sredstva M4; depozitni novac; plasmani; rashodi državnog proračuna, ukupno.

$\sum_{j=1}^k \beta_j L_{t-j}$ regresija referentne serije na “lagirane” vrijednosti potencijalnog prethodećeg pokazatelja (Leading Indicators). Detalje vidjeti u: A. Ahec-Šonje, ur. (2000).

⁶ Za podroban opis kriterija ocjenjivanja vidjeti: A. Ahec-Šonje, ur., (2000).

Tablica 1.

"ŠIRA" LISTA NAVJEŠĆUJUĆIH INDIKATORA

Naziv pokazatelja	Vrijeme prethođenja
S 20 Indeks fizičkog obujma industrijske proizvodnje, izdavačka i tiskarska djelatnost	(t-9)
S 39 Indeks fizičkog obujma potrošnje u industriji energije i goriva	(t-9)
S 45 Novoprijavljeni radi zaposlenja u tijeku mjeseca	(t-5)
S 46 Nezaposlene osobe prema stanju na svršetku mjeseca	(t-6)
S 48 Zaposleni s evidencije u tijeku mjeseca	(t-10)
S 49 Prijavljene potrebe za radnicima u tijeku mjeseca	(t-7)
S 54 Broj noćenja turista, ukupno	(t-7)
S 55 Broj noćenja stranih turista	(t-7) i (t-8)
S 56 Broj noćenja domaćih turista	(t-10)
S 57 Promet u trgovini na malo	(t-2)
S 75 Izvoz životinjskih i biljnih ulja i masti	(t-6)
S 78 Izvoz strojeva i transportnih uređaja	(t-4)
S 81 Uvoz robe, ukupno	(t-6)
S 88 Uvoz mineralnih goriva i maziva	(t-5)
S 92 Uvoz strojeva i transportnih uređaja	(t-4) i (t-5)
S 95 Nekonsolidirani prihodi državnog, županijskih i općinskih proračuna	(t-5)
S 98 Masa neto plaća, ukupno	(t-8)
S 104 Novčana sredstva sudionika u platnom prometu, ukupno	(t-12)
S 105 Novčana masa M1	(t-12)
S 107 Ukupna likvidna sredstva M4	(t-10)
S 108 Primarni novac	(t-8)
S 110 Depozitni novac	(t-10)
S 115 Štedni i oročeni depoziti kod poslovnih banaka, devizni-poduzeća	(t-11)
S 116 Plasmani	(t-10) do (t-12)
S 123 Devizne rezerve poslovnih banaka, oročeni depoziti i depoziti s otkaznim rokom	(t-3)
S 148 Porezni prihod - carine, carinske i uvozne pristojbe	(t-7)
S 157 Rashodi državnog proračuna - ukupno	(t-7)

Tablica 2.

PRIMJER "SCORING" OCJENJIVANJA - S105
 NOVČANA MASA M1

KRITERIJ OCJENJIVANJA	OCJENA
(1) Ekonomska značajnost (20%)	100
(2) Statistička pouzdanost (20%)	
a) statistički obuhvat	20
b) sustav izvještavanja	20
c) učestalost promjena metodološkog obuhvata	5
d) kvaliteta metodološkog objašnjenja	20
e) dužina serije	10
f) usporedivost serije u vremenu	10
(3) Izgladenost serije (20%) MCD	100
(4) Ažurnost u prikupljanju i objavi podataka (10%)	100
(5) Ekonomska utemeljenost veze (30%) korigirani koeficijent determinacije R2*	80
UKUPNA OCJENA	91

Šira lista pokazatelja osnovica je za nastavak eliminacije serija, da bi se došlo do desetak varijabli s najboljim prognostičkim obilježjima, tj. do onih koje su "izgladene" i imaju dugački "lead-time". Logika i kriteriji "scoring" sustava ocjenjivanja pobrinut će se da takve serije dobiju najvišu moguću ocjenu, čime one postaju ozbiljni kandidati za komponente CROLEI indeksa. Ocjenjuje se svih 27 potencijalnih "leadera" prema spomenutim kriterijima ocjenjivanja. Tablica 2. pruža primjer ocjenjivanja jednog od pokazatelja sa šire liste, u tablici 3. prikazani su konačni rezultati procjene svih 27 indikatora šire liste, a tablica 4. rangira pokazatelje prema konačnim "scoring" ocjenama.

Tablica 3.

KONAČNE OCJENE POKAZATELJA SA ŠIRE LISTE

KRITERIJ OCJENJIVANJA						
Seriya	Ekonomska značajnost 20%	Statistička pouzdanost 20%	Izgladenost serije 20%	Ažurnost u prikupljanju i objavi podataka 10%	Ekonomska utemeljenost veze 30%	Ukupna ocjena
S 20	80	85	20	100	80	71
S 39	80	85	0	60	80	63
S 45	80	100	0	100	80	70
S 46	100	100	100	100	80	94
S 48	80	100	60	100	90	85
S 49	80	100	60	100	80	82
S 54	100	100	60	60	90	85
S 55	80	100	60	60	80	78
S 56	80	100	20	60	90	73
S 57	100	60	80	60	80	78
S 75	80	85	0	60	80	63
S 78	80	85	0	60	30	48
S 81	100	85	0	60	30	52
S 88	80	85	0	60	80	63
S 92	80	85	0	60	30	48
S 95	100	85	20	60	80	71
S 98	100	85	80	60	80	83
S 104	100	85	80	60	90	86
S 105	100	85	100	100	80	91
S 107	100	85	100	100	80	91
S 108	80	85	100	100	30	72
S 110	80	85	80	100	80	83
S 115	60	75	60	100	90	76
S 116	100	85	80	100	30	72
S 123	80	75	80	100	30	66
S 148	80	85	20	100	90	74
S 157	100	85	20	100	80	75

Tablica 4.

RANGIRANJE SERIJA PREMA "SCORING" OCJENAMA

Redoslijed	Seriya	Ukupna ocjena
1	S 46	94
2	S 105	91
3	S 107	91
4	S 104	86
5	S 48	85
6	S 54	85
7	S 98	83
8	S 110	83
9	S 49	82
10	S 55	78
11	S 57	78
12	S 115	76
13	S 157	75
14	S 148	74
15	S 56	73
16	S 108	72
17	S 116	72
18	S 20	71
19	S 95	71
20	S 45	70
21	S 123	66
22	S 39	63
23	S 75	63
24	S 88	63
25	S 81	52
26	S 78	48
27	S 92	48

Uspoređujući tablicu 4. s redoslijedom pokazatelja nakon revizije godine 1997., uočava se bitno poboljšanje statističke kvalitete serija koje su ušle u širi izbor pokazatelja. Ovogodišnja prvorangirana serija ima maksimalnu ocjenu 94 (od ukupno 100) za razliku od prve na listi iz godine 1997. koje je najveća ocjena bila 87. Poboljšanje se vidi i na začelju liste, tako ovogodišnja "najlošija" prethodeća

serija ima ocjenu 48, za razliku od najloše plasirane serije iz godine 1997., koje je ocjena bila 44. Navedeno se poboljšanje odrazilo na porast ukupne prosječne ocjene svih pokazatelja šire liste sa 68 na 74.

Izbor uže liste ili kandidata za CROLEI indeks uobičajeno se zasniva na osnovnim zahtjevima kako slijedi: niska, zanemariva iregularna komponenta u kretanju serije, visoka "scoring" ocjena gdje se kao donja granica za izbor uzima ocjena 70, dovoljno dug "lead-time" serije, prioritet pri izboru imaju ekonomski agregati.

Nijedna serija s liste koja ima ocjenu manju od 70 ne može ući u CROLEI indeks. Ocjena je odraz kvalitete svake pojedine serije dobivena primjenom svih navedenih kriterija. Vodeći računa o navedenim zahtjevima, užu listu čine uglavnom agregati, izglađene serije s dužim "lead" vremenom i pritom valja paziti da u indeks ne uđu predstavnici iste ekonomske aktivnosti, ali na različitim stupnjevima agregiranosti. Dakle, metodološki je izdvojeno 10 novih komponenti revidiranog CROLEI⁰⁰ indeksa, koje će utjecati na prognostičku vrijednost indeksa sve do naredne revizije. Nove komponente prognostičkog indeksa s pripadajućim vremenom prethođenja, ocjenama i ponderima značajnosti prikazane su u tablici 5. i tablici 6.

Tablica 5.

KOMPONENTE REVIDIRANOG SLOŽENOG INDEKSA CROLEI⁰⁰

Naziv pokazatelja	Vrijeme prethođenja
S 48 Zaposleni s evidencije u tijeku mjeseca	(t-10)
S 49 Prijavljene potrebe za radnicima u tijeku mjeseca	(t-7)
S 54 Broj noćenja turista, ukupno	(t-7)
S 57 Promet u trgovini na malo	(t-2)
S 95 Nekonsolidirani prihodi državnog, županijskih i općinskih proračuna	(t-5)
S 98 Masa neto plaća, ukupno	(t-8)
S 104 Novčana sredstva sudionika u platnom prometu, ukupno	(t-12)
S 107 Ukupna likvidna sredstva M4	(t-10)
S 115 Štedni i oročeni depoziti kod poslovnih banaka, devizni-poduzeća	(t-11)
S 116 Plasmani	(t-10)

Tablica 6.

OCJENE I PONDERI ZNAČAJNOSTI KOMPONENTI CROLEI¹⁰⁰ INDEKSA

Seriya	Ekonomska značajnost 20%	Statistička pouzdanost 20%	Izgladenost serije 20%	Ažurnost u prikupljanju i objavi podataka 10%	Ekonomska utemeljenost veze 30%	Ukupna ocjena (Si)	Ponder (Wi)	Prosječni "lead-time"
S 48	80	100	60	100	90	85	1,0507	-10,5
S 49	80	100	60	100	80	82	1,0136	- 7
S 54	100	100	60	60	90	85	1,0507	- 7,4
S 57	100	60	80	60	80	78	0,9642	- 2
S 95	100	85	20	60	80	71	0,8776	- 4,4
S 98	100	85	80	60	80	83	1,0259	- 8,2
S 104	100	85	80	60	90	86	1,0630	-12,8
S 107	100	85	100	100	80	91	1,1248	-11,2
S 115	60	75	60	100	90	76	0,9394	-10,3
S 116	100	85	80	100	30	72	0,8899	- 8,9
UKUPNO						809	10	-82,7
Prosjeck*						80,9		-8,27

* Prosječno vrijeme prethođenja CROLEI indeksa = $\Sigma(t-m)_i \cdot Wi/k$, gdje je m broj mjeseci prethođenja, $i=1,2,\dots,k$, gdje je k ukupan broj serija koje čine složeni indeksi (u našem slučaju $k=10$), a Wi je ponder svakog pojedinog indikatora i .

“Scoring” sustav pobrinuo se da u revidirani indeks uđu serije s najboljim obilježjima: ažurne i izglađene serije s malim zaostatkom u objavljivanju, serije koje nisu podložne čestim revizijama i koje zastupaju najznačajnija područja ekonomske aktivnosti u Hrvatskoj i one serije koje imaju dovoljno dugo vrijeme prethođenja.

Za izračunavanje najnovijeg CROLEI indeksa i dalje se koristimo standardiziranim metodološkim okvirom razvijenim u okviru NBER-a i BEA/US Department of Commerce. To je jedini dio metode indikatora koji dosad nije doživio veće izmjene i već godinama se u izvornom obliku upotrebljava za ponderiranje komponenti u složeni prognostički indeks (Zarnowitz i Boschan, 1975.; Gapinski, 1982.; Shiskin, 1961.). Taj se pokazatelj može promatrati kao “vagana” sredina pojedinačnih navješćujućih pokazatelja, a to samo potvrđuje bitnu jednostavnost metode indikatora. Premda odražava amplitudu i smjer promjena svake njegove komponente, složeni indeks ipak “izglađuje” njihove slučajne oscilacije. Stoga se njegovim korištenjem u prognostičke svrhe smanjuje mogućnost davanja krivih prognoza upotrebom samo jednog navješćujućeg pokazatelja.

Umjesto zaključka: što pokazuje novi CROLEI indeks

Obično je složeni (kompozitni) indeks navješćujućih indikatora pouzdaniji ciklički indikator od svojih pojedinačnih komponenti. Zbog načina na koji nastaje, svog širokog i raznolikog obuhvata, taj je indeks manje podložan iregularnim kretanjima i hirovitim oscilacijama, što može biti problem na razini svakog pojedinog indikatora. Dosad korišten CROLEI⁹⁹ indeks odražavao je prosječno kretanje desetak najboljih navješćujućih indikatora koji su pokrivali različite ekonomske aktivnosti od zaposlenosti, turizma, trgovine, do fiskalnog i monetarnog segmenta. Prosječno vrijeme prethođenja dosadašnjeg prognostičkog indeksa iznosilo je 8.2 mjeseca u odnosu na izabranu referentnu seriju.

Revizija statističke baze i “scoring” metode rezultirala je izborom deset “novih” prethodećih pokazatelja, koji, osim što zadovoljavaju odgovarajući ciklički obrazac ponašanja, i dalje pokrivaju širok spektar najznačajnijih ekonomskih aktivnosti u zemlji. U novom indeksu nalazimo čak sedam ekonomskih agregata, a u prethodnom ih je bilo pet. Da bi indeks realno odražavao globalnu ekonomsku aktivnost morao bi uključivati što više agregata koji predstavljaju gotovo sve najznačajnije ekonomske procese u zemlji. Stoga je u odnosu na ovaj zahtjev revizijom učinjen određen kvalitativni pomak u smjeru poboljšanja analitičkih i prognostičkih vrijednosti indeksa. I ovog je puta postupak izračunavanja indeksa spriječio dominaciju “hirovitih” serija, pa su izabrani “izglađeni” pokazatelji kojima dominira trend-ciklus komponenta.

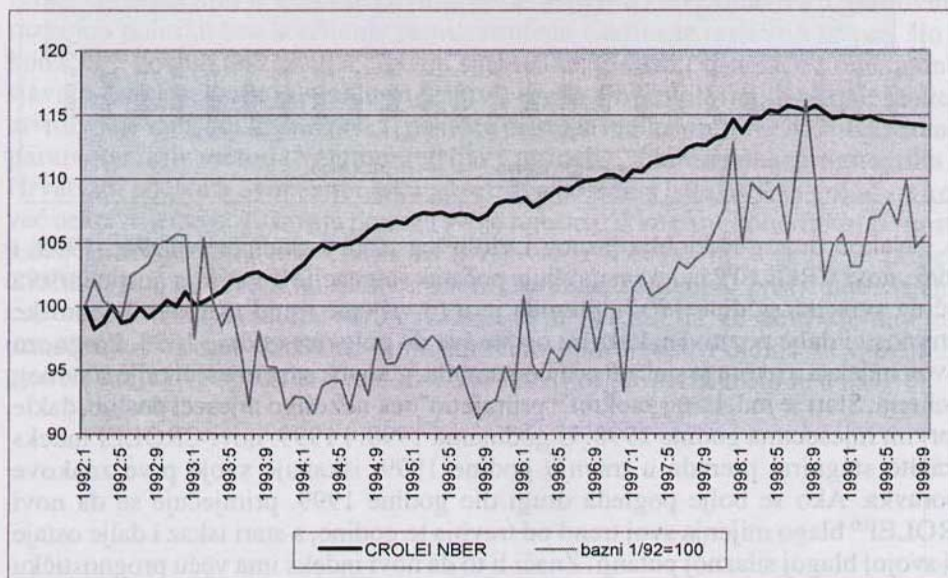
Positivna informacija dobivena nakon revizije svakako je ona o udjelu šest dosadašnjih komponenti indeksa u novom revidiranom CROLEI iskazu, a to opravdava dalju upotrebu i vjerodostojnost metode indikatora i u našem ekonomskom okruženju. Prema standardima metode to je znak veoma stabilne i visokosigni-

fikantne usuglašenosti između utvrđenih navješćujućih pokazatelja i kretanja referentne serije koja se prati, što predstavlja veliku pomoć u predviđanju ukupne gospodarske aktivnosti u Hrvatskoj.

Prosječno vrijeme prethođenja novog indeksa u odnosu na stari nije bitno promijenjeno, pa i dalje iznosi 7-8 mjeseci. Bez obzira što je prosječan "lead-time" novih komponenti indeksa prilično dugačak, pri iznošenju prognostičkih iskaza uvijek je potreban značajan oprez. Svaka se prognoza osniva na opreznom tumačenju utvrđenog "lead-time" i polazi od pravila tromjesečnog uzastopnog istosmjernog kretanja CROLEI indeksa. O odstupanjima u kretanju novog i starog indeksa najbolje će posvjedočiti slika 2.

Slika 2.


USPOREDBA DOSADAŠNJEG I REVIDIRANOG CROLEI INDEKSA



Slika 2. jasno upućuje na zaključak da oba indeksa imaju veoma sličan ciklički obrazac kretanja i da su prilično usuglašeni u promatranom razdoblju od godine 1992.-1999. Revidirani indeks ipak jasnije i transparentnije odražava predstabilizacijsko i poststabilizacijsko razdoblje u Hrvatskoj za razliku od dosadašnjeg indeksa. Kod novog je iskaza taj prvi pozitivni zaokret u hrvatskom gospodarstvu jasnije izražen, s prijelomom u listopadu godine 1993., kada je donesen stabilizacijski program. Nakon godine 1993. oba prognostička iskaza snažno su usuglašena u svom kretanju, razlika gotovo i nema, sve do krizne godine 1999. Pogledajmo odmah i narednu sliku na kojoj su prikazani novi prognostički indeks i referentna serija - industrijska proizvodnja u razdoblju od godine 1992. do 1999.

Slika 3.

CROLEI I INDUSTRIJSKA PROIZVODNJA



Nakon dugog razdoblja jasnog i vidljivog rasta u godinama 1994., 1995. i 1996., novi CROLEI⁰⁰ indeks najavljuje početak stagnacije hrvatskog gospodarstva već na svršetku godine 1997., premda je u to vrijeme trend ukupne ekonomske aktivnosti i dalje pozitivan, kakvim ostaje sve do polovice godine 1998. Prognoza novog indeksa u ovom je slučaju prilično uranila, gotovo osam mjeseci prije stvarnog zaokreta. Stari je indeks taj zaokret "primijetio" tek nekoliko mjeseci poslije, dakle u prvim mjesecima godine 1998. U godinama 1998. i 1999. novi CROLEI indeks izrazito stagnira, premda u travnju godine 1999. iskazuje svoje prve znakove oporavka. Ako se bolje pogleda drugi dio godine 1999. primjećuje se da novi CROLEI⁰⁰ blago mijenja svoj trend od travnja te godine, a stari iskaz i dalje ostaje pri svojoj blagoj silaznoj putanji. Znači li to da novi indeks ima veću prognostičku snagu i može li se promjena trenda u drugoj polovini godine 1999. tumačiti kao najava oporavka hrvatskog gospodarstva već u prvom polugodištu 2000. godine? Naznake da je to tako već postoje, a to možemo zamijetiti prema znakovima ponovnog uspona industrijske proizvodnje u posljednjem tromjesečju prošle i u prva dva mjeseca ove godine, uz naglasak da najnoviji trend rasta industrije još uvijek ima veoma nestabilne karakteristike. To potvrđuje i prilično "sramežljiv" uspon prognostičkog indeksa u drugom polugodištu prošle godine.

Razlozi za zadovoljstvo dosad postignutim rezultatima razvitka CROLEI sustava višestruki su. S jedne strane, to je činjenica da novi, revidirani prognostički indeks nije diskvalificirao dosadašnji, o čemu svjedoči njihovo ustrajno usuglašeno kretanje u promatranom analitičkom razdoblju. Sa druge strane, čini se da je izborom

novih komponenti indeksa (premda je gotovo polovna njih iz dosadašnjeg sustava) došlo do povećanja prognostičke snage i vrijednosti CROLEI indeksa. Ponovni izbor dijela pokazatelja iz starog sustava veliki je plus za samu metodu i potvrđuje njezinu vjerodostojnost i upotrebljivost u analizi i prognozi hrvatskoga gospodarstva i u budućnosti.

Ekonomске stručnjake u Hrvatskoj danas ipak više mora zabrinjavati mogućnost daljeg razvitka i usavršavanja sofisticiranih analitičkih metoda koje pomažu pri utvrđivanju skrivenih veza u gospodarstvu. Tu bi prije svega ključnu ulogu morala odigrati državna statistika koja svojom presporom prilagodbom ubrzanim tranzicijskim procesima postaje ograničenje za razvitak takvih metoda analize. Drugi je ključni element "osvještenost" ekonomske javnosti o potencijalnim koristima oslanjanja na stručne ekonomske analize i informacije, ako one, naravno, postoje. Konkurencija na tom području, području ekonomskih istraživanja i primjene različitih metoda analiza dovela bi do njihovog još bržeg razvitka i podizanja kvalitete. U razvijenim je gospodarstvima nezamislivo voditi ekonomsku, poslovnu i razvojnu politiku bez korištenja raznih stručnih analiza iz različitih izvora, što je konačno i dovelo do razvitka čitavog spektra analitičkih pristupa, od onih jednostavnih (ankete, razni konjunktorni testovi) preko složenijih (input-output tablice, utvrđivanje statističkih pravilnosti pomoću pristupa indikatora), sve do sofisticiranih parametarskih metoda (ekonometrijski modeli). Ekonomska prognostika u Hrvatskoj počiva u ovome trenutku na tek dva pojedina istraživačka pokušaja koji već neko vrijeme pokušavaju pronaći svoje mjesto u domaćoj ekonomskoj javnosti: jedan je konjunktorni test Centra za istraživanja konjunktura, a drugi je projekt CROLEI koji se izvodi na Ekonomskom institutu, Zagreb. U posljednje vrijeme sve veći interes međunarodnih financijskih institucija za objavljivanjem i tumačenjem iskaza CROLEI budi određeni optimizam o budućem razvitku i usavršavanju ove specifične makroekonomske prognostičke metode u nas.

DODATAK A.
STATISTIČKI DODATAK

Series	MCD	MCD span	Relative contribution of components				Total	FINAL I/C	FINAL I/S	Final results of SA-method			Measures failed
			I	C	S	S				level			
S01	4	0,88	7,93	45,16	46,19	102,76	0,18	0,17	A		0,53	0	
S02	12	1,17	38,51	13,26	44,96	96,72	2,90	0,86	R		1,52	6	
S03	4	0,93	6,76	28,88	60,10	99,84	0,23	0,11	A		0,57	0	
S04	6	0,88	19,90	38,33	48,61	106,84	0,52	0,41	R		1,01	3	
S05	5	0,95	17,54	9,35	74,73	101,63	1,88	0,23	A		0,95	3	
S06	4	0,96	11,54	16,71	59,91	90,24	0,69	0,19	A		0,62	2	
S07	5	0,92	22,18	48,57	28,53	101,01	0,46	0,78	R		1,08	3	
S08	5	0,95	26,39	52,38	20,95	102,32	0,50	1,26	R		1,46	8	
S09	4	0,92	9,83	42,05	43,06	98,22	0,23	0,23	A		0,72	4	
S13	5	0,92	12,33	11,83	75,58	102,31	1,04	0,16	A		0,74	2	
S20	5	0,77	14,54	74,92	9,29	98,75	0,19	1,67	R		1,28	7	
S22	12	1,01	34,20	25,53	30,41	90,14	1,34	1,12	R		1,87	8	
S24	5	0,95	8,37	8,96	89,47	106,80	0,93	0,09	A		0,53	0	
S26	9	0,91	24,69	50,36	24,29	101,61	0,49	1,01	R		1,29	5	
S38	1	0,27	2,79	75,91	29,90	108,60	0,04	0,09	A		0,38	0	
S39	12	1,18	13,49	7,53	77,29	98,31	1,79	0,17	R		1,01	2	
S40	3	0,88	4,38	75,42	7,37	88,06	0,06	0,59	R		1,04	6	
S41	3	0,82	9,03	45,42	45,11	102,82	0,20	0,20	A		0,52	0	
S42	1	0,99	2,48	89,10	4,47	95,95	0,03	0,55	A		0,73	4	
S44	1	0,90	2,24	90,75	1,68	94,67	0,02	1,33	A		0,92	5	
S45	8	0,87	8,93	7,50	84,67	101,10	1,19	0,11	A		0,67	1	
S46	1	0,65	0,39	88,25	9,75	98,40	0,00	0,04	A		0,37	0	
S47	2	0,67	1,69	15,43	87,89	105,01	0,11	0,02	A		0,21	0	
S48	3	0,97	8,11	23,28	65,43	96,82	0,35	0,12	A		0,66	2	
S49	3	0,95	5,75	18,56	71,67	95,98	0,31	0,08	A		0,51	0	
S50	5	0,89	13,69	48,25	36,32	98,26	0,28	0,38	A		0,94	4	
S51	1	0,39	0,43	93,92	2,70	97,05	0,00	0,16	A		0,55	3	

STATISTIČKI DODATAK

Series	MCD	MCD span	Relative contribution of components			FINAL		FINAL results of SA-method		Measures failed	
			I	C	S	Total	I/S	A			
S52	1	0,42	100,05	0,32	100,85	0,00	1,60	A	0,88	5	
S54	3	0,87	1,62	139,20	141,78	0,59	0,01	A	0,14	1	
S55	3	0,75	0,83	2,12	143,96	146,91	0,39	0,01	A	0,14	0
S56	5	0,98	0,98	2,00	123,52	126,59	0,49	0,01	A	0,33	0
S67R	2	0,57	1,12	68,80	28,31	98,90	0,02	0,04	A	0,18	0
S68R	1	0,54	0,30	99,19	0,72	100,21	0,00	0,42	A	0,68	5
S67	12	1,35	67,75	20,05	16,47	96,69	2,88	3,51	R	1,97	6
S71	12	1,25	52,61	27,70	19,14	106,16	1,90	2,75	R	1,96	9
S72	12	2,16	69,08	22,66	18,43	110,16	3,05	3,75	R	2,43	9
S73	12	2,23	64,32	8,60	44,28	117,20	7,48	1,45	R	2,10	9
S74	12	1,19	45,20	29,25	19,03	94,84	1,55	2,38	R	2,03	8
S75	6	0,86	36,77	46,43	26,48	109,68	0,79	1,39	R	1,63	7
S76	12	1,09	38,74	33,70	12,67	88,15	1,15	3,06	R	2,27	9
S77	12	1,13	52,00	28,42	18,88	101,71	1,83	2,75	R	1,83	6
S78	12	1,42	59,07	19,51	32,40	110,99	3,03	1,82	R	2,15	9
S79	12	2,42	61,26	8,34	12,72	84,03	7,35	4,82	R	2,23	9
S80	12	1,07	58,58	79,99	16,33	153,89	0,73	3,82	R	2,05	9
S81	12	1,03	44,52	29,48	15,40	89,40	1,51	2,89	R	1,97	8
S86	6	0,65	22,66	63,35	11,34	97,36	0,36	2,00	R	1,51	7
S86	12	1,24	36,64	15,12	38,72	90,48	2,42	0,95	R	1,89	9
S87	7	0,88	37,91	48,72	9,22	95,85	0,78	4,11	R	1,79	8
S88	12	3,33	49,86	9,91	34,38	94,15	6,03	1,45	R	2,35	9
S89	12	1,42	45,05	24,57	24,49	94,11	1,83	1,84	R	1,89	8
S90	4	0,91	24,74	50,23	14,57	90,56	0,49	1,70	R	1,40	6
S91	5	0,96	31,51	53,36	13,46	99,50	0,59	2,34	R	1,36	4
S92	7	0,94	42,02	30,97	18,83	91,82	1,36	2,23	R	1,62	8
S93	12	1,95	51,87	15,82	27,45	96,06	3,28	1,89	R	2,03	9
S94	12	44,27	86,10	4,29	3,48	93,88	20,07	24,74	R	2,39	9

STATISTIČKI DODATAK

Series	MCD	MCD span	Relative contribution of components			FINAL			Final results of SA-method	Measures failed	
			I	C	S	Total	I/C	I/S			J/S
S95R	5	0,71	17,50	52,66	25,26	96,42	0,33	0,69	R	1,15	4
S96R	3	0,97	9,13	86,55	7,14	102,82	0,11	1,28	R	1,17	6
S97R	4	0,84	6,59	53,20	40,80	101,42	0,12	0,16	A	0,54	0
S98R	2	0,94	6,94	81,04	4,89	92,57	0,08	1,36	R	1,21	6
S99R	4	0,68	9,08	33,21	48,16	91,51	0,27	0,19	A	0,56	0
S100R	4	0,77	8,39	49,19	35,51	94,26	0,17	0,24	A	0,58	1
S101R	2	0,91	4,75	59,67	37,50	103,91	0,08	0,13	A	0,44	0
S102R	1	0,95	1,98	94,53	1,28	97,78	0,02	1,55	R	1,09	5
S103R	3	0,86	6,36	57,86	33,96	100,20	0,11	0,19	A	0,51	1
S104R	2	0,60	2,60	94,22	2,92	99,74	0,03	0,89	A	0,59	3
S106R	1	0,88	1,18	91,55	2,12	94,85	0,01	0,56	A	0,63	4
S106R	1	0,79	0,96	92,21	2,96	96,13	0,01	0,32	A	0,43	0
S107R	1	0,86	6,12	91,39	0,73	98,23	0,07	8,38	R	1,14	5
S108R	1	0,97	1,32	98,89	1,97	102,18	0,01	0,67	A	0,47	0
S109R	2	0,56	1,78	93,52	2,72	98,02	0,02	0,66	A	0,58	2
S110R	2	0,56	2,75	86,11	2,67	91,53	0,03	1,03	A	0,83	6
S111R	4	0,68	12,38	82,48	8,20	103,05	0,15	1,51	R	1,35	4
S112R	1	0,65	1,34	91,56	2,73	95,63	0,01	0,49	A	0,50	2
S113R	1	0,30	0,50	91,76	1,48	93,74	0,01	0,34	A	0,30	0
S114R	1	0,27	0,41	94,86	0,92	96,18	0,00	0,45	A	0,27	1
S115R	3	0,69	9,20	59,23	16,85	85,27	0,16	0,55	A	0,75	2
S116R	2	0,61	2,87	86,63	0,91	90,40	0,03	3,15	R	1,25	6
S117R	1	0,72	5,49	86,19	1,62	93,30	0,06	3,39	A	0,79	2
S118R	1	0,99	10,32	69,44	1,44	81,20	0,15	7,17	R	1,08	4
S119R	1	0,21	0,66	97,89	0,59	99,15	0,01	1,12	A	0,41	1
S120R	1	0,94	3,22	100,24	0,26	103,72	0,03	12,38	R	1,30	5
S121R	1	0,85	1,32	96,68	2,03	100,06	0,01	0,65	A	0,58	1
S122R	2	0,56	2,66	96,82	1,01	100,49	0,03	2,63	A	0,81	2

STATISTIČKI DODATAK

Series	MCD	MCD span	Relative contribution of components				FINAL		FINAL results of SA-method		Measures failed
			I	C	S	Total	I/C	I/S	A	R	
S123R	2	0,76	3,10	84,30	4,76	92,16	0,04	0,65	A	0,80	2
S124R	2	0,63	4,50	88,02	1,09	93,61	0,05	4,13	R	1,11	3
S140R	4	0,84	18,63	45,52	23,11	87,26	0,41	0,81	R	1,28	7
S141R	3	0,98	25,94	70,07	7,37	103,38	0,37	3,52	R	1,66	7
S143R	4	0,87	15,25	67,03	21,66	93,94	0,27	0,70	R	1,12	5
S144R	12	1,08	41,57	12,77	98,68	163,02	3,26	0,42	R	1,32	3
S145R	2	0,81	3,86	79,01	8,85	91,72	0,05	0,44	A	0,65	3
S148R	5	4,18	11,79	43,85	33,25	88,89	0,27	0,35	A	0,69	2
S149R	7	0,86	35,67	24,83	33,07	93,57	1,44	1,08	R	1,68	6
S150R	10	0,87	44,72	27,46	16,36	88,54	1,63	2,73	R	1,96	6
S156R	8	0,98	25,66	70,42	9,45	105,53	0,36	2,72	R	1,64	8
S157R	5	0,93	27,63	51,36	21,34	100,33	0,54	1,29	R	1,41	6
S159R	6	0,84	45,18	52,74	7,77	105,69	0,86	5,81	R	2,03	3
S160R	5	0,95	30,78	47,52	25,41	103,71	0,65	1,21	R	1,52	2
S161R	12	4,12	59,95	1,49	48,98	110,42	40,23	1,22	R	2,19	5
S162R	8	0,86	77,48	9,24	8,22	94,95	8,39	9,43	R	2,29	5
S163R	12	1,48	61,96	19,30	24,78	106,04	3,21	2,50	R	2,12	6
S164R	9	0,90	32,47	10,90	54,27	97,64	2,98	0,60	R	1,57	5

DODATAK B.

Tablica 1.

Ekonomska značajnost serija*

(a) Agregat	100
(b) Podagregat	80
(c) Usko definirani pokazatelji	60
- Uz ponder značajnosti od 20% maksimalna je ocjena prema ovom kriteriju	20

* Procjenjuje se širina obuhvata pojedinih ekonomskih pokazatelja; poželjno je da u sustav indikatora uđu agregati koji dovoljno široko obuhvaćaju ekonomski proces koji predstavljaju.

Tablica 2.

Statistička pouzdanost*

a) Statistički obuhvat serije	
i) cijela populacija (90-100%)	20
ii) uzorak	
(1) reprezentativni	15
(2) ostali	5
b) Sustav izvještavanja	
i) direktni	20
ii) administrativni izvori	10
iii) procjene	0
c) Učestalost promjena metodološkog obuhvata	
i) nema promjena u razdoblju 1992.-1999.	20
ii) jedna ili više promjena u promatranom razdoblju	5
d) Kvaliteta metodološkog objašnjenja	
i) zadovoljavajuća	20
ii) nezadovoljavajuća	5
e) Dužina serije	
i) 1/92 - nadalje	10
ii) kraće serije	0
f) Usporedivost serije u vremenu	
i) podaci su usporedivi u različitim vremenskim razdobljima	10
ii) podaci nisu usporedivi zbog promjene obuhvata podataka	0
- Uz ponder značajnosti od 20% maksimalna ocjena prema ovom kriteriju jest	20

* Ocjenjuje se kvaliteta statističkih izvora.

Tablica 3.

Konzistentnost u prethođenju*

R2*	
0.85-1	100
0.80-0.849	90
0.70-0.799	80
0.65-0.699	70
0.60-0.649	60
0.55-0.599	50
0.50-0.549	40
0.00-0.499	0
- Uz ponder značajnosti od 30% maksimalna ocjena prema ovom kriteriju jest	30

* Granger test uzročnosti ima značajan ponder pri ocjenjivanju i izboru "leading" indikatora za industriju. Uz pomoć testa otkrivamo najbolje "leadere" među serijama, utvrđujemo "lead time" i ocjenjujemo "jakost" veze između referentne serije i indikatora. Kao mjera jakosti veze koristi se prilagođeni (korigirani) koeficijent determinacije R2* (korigiran brojem stupnjeva slobode brojnika, tj. sume objašnjenih kvadrata odstupanja, i nazivnika, tj. sume ukupnih kvadrata odstupanja).

Tablica 4.

Izgladenost serije

MCD*	
1	100
2	80
3	60
4	40
5	20
6 i više	0
- Uz ponder značajnosti od 20% maksimalna ocjena prema ovom kriteriju jest	20

* MCD (months for cyclical dominance) - broj mjeseci u kojem prosječna postotna promjena cikličke komponente premašuje prosječnu postotnu promjenu iregularne komponente.

NAPOMENA: Mjerom MCD ocjenjujemo izgladenost serije i cikličku signifikantnost u razvitku tendencije serije ako se radi o mjesečnim podacima (u slučaju kvartalnih podataka koristile bi se druge mjere, primjerice odnos iregularne i cikličke komponente I/C). Te mjere "izbacuje" program za desezoniranje vremenskih serija X11ARIMA2000 - Statistics Canada (vidjeti u DODATKU A.).

Tablica 5.

Ažurnost statističke podloge*

(a) Podaci dostupni do 21. u mjesecu za prethodni mjesec	100
(b) Do 21. u mjesecu za pretprethodni mjesec	60
(c) Dnevni, tjedni ili desetodnevni podaci	0
- Uz ponder značajnosti od 10% maksimalna ocjena prema ovom kriteriju jest	10

* Ocjenjuje se brzina dostupnosti podataka; svako veće kašnjenje u objavi podataka dovodi u pitanje vrijednost dobivenih prognostičkih iskaza.

LITERATURA:

1. *Ahec-Šonje, A.* (ur.) i grupa autora: "Revizija prognostičkog indeksa CROLEI", Završna studija, Ekonomski institut, Zagreb, 1997.
2. *Ahec-Šonje, A.* (ur.) i grupa autora: "Revizija CROLEI indeksa (1992-1999)", Osnovna studija, Ekonomski institut, Zagreb, 2000.
3. *Dyckman, T.R. i H.O. Stekler*: "Probabilistic Turning Point Forecasts", *The Review of Economics and Statistics*, 48, 1966., str. 288-295.
4. *Gapinski, James H.*: "Macroeconomic Theory: Statics, Dynamics, and Policy", McGraw-Hill, New York, 1982.
5. *Moore, G.H. & J. Shiskin*: "Indicators of Business Expansions and Contractions", NBER, New York, 1967.
6. *Niemira, M. P. & Philip A. Klein*: "Forecasting Financial and Economic Cycles", Wiley&Sons, New York, 1994.
7. *Shiskin, J.*: "Signals of Recession and Recovery: An Experiment with Monthly Reporting", NBER, New York, 1961.
8. *Stekler, H.O.*: "Turning Point Predictions, Errors and Forecasting Procedures" u Lahiri, K. i G.H. Moore: "Leading Economic Indicators: New Approaches and Forecasting Records", Cambridge University Press, Cambridge, 1991., str. 169-181.
9. U.S Department of Commerce, Bureau of Economic Analysis: "Handbook of Cyclical Indicators", Government Printing Office, Washington, D.C., 1977.
10. *Zarnowitz, V. & C. Boschan*: "Cyclical Indicators: An Evaluation and New Leading Indexes" u U.S. Department of Commerce, BEA (1977), Handbook of Cyclical Indicators, 1975.
11. *Zarnowitz, V.*: "Business Cycles: Theory, History, Indicators, and Forecasting", The University of Chicago Press (za NBER), Chicago, 1992.

ECONOMIC FORECAST IN CROATIA: CROLEI index

Summary

In developed economies it is inconceivable to conduct economic, business and development policy without relying upon professional analytical methods, what finally brought to development of the whole spectrum of analytical approaches, from the simplest ones (inquiries, economic tests), across more compound (input-output tables, leading indicators approach), all to sophisticated parameter methods and models. At this moment economic forecast in Croatia is mainly rooted in the forecast report CROLEI, which methodologically relies upon the leading indicators approach founded by the known American research institution NBER. Development of leading indicators system in Croatia started six years ago, in conditions in which it was objectively not possible, due to too short time series, to build domestic sophisticated econometric model for economic analysis and forecast.

In this paper the author stresses why is the indicators method simple and popular technique of the analysis and forecast of economic fluctuations, indicating the reasons and causes of made interventions during the last auditing at the end of 1999. Comparing behaviour of the forecast index before and after the implemented auditing, the author emphasizes numerous analytical and forecast advantages of new revised index in comparison with the past one. The quality and credibility of leading indicators domestic system increasingly grows in the course of time, what arouses optimism in view of future development of this specific forecast method in this country.