

ČLANCI

CROLEI U NOVOME RUHU: TREBA LI NAM NOVI PROGNOSTIČKI INDEKS?

mr. sc. Katarina BAČIĆ*
Ekonomski institut, Zagreb

Izvorni znanstveni članak**
UDK 311(497.5)
JEL E32, E37

mr. sc. Maruška VIZEK*
Ekonomski institut, Zagreb

Sažetak

Cilj je rada utvrditi omogućuje li postojeći prognostički sustav i njegov rezultat, prognostički indeks CROLEI, pouzdano predviđanje ukupnih gospodarskih kretanja u Hrvatskoj. Potreba da se sustav i indeks vrednuju potječe iz modifikacije barometarske metode na kojoj se sustav i indeks zasnivaju i primjenjuju. Proces vrednovanja prognostičke moći započinje konstruiranjem šest alternativnih prognostičkih indeksa na osnovi barometarske metode, koji osim što konkuriraju izvornome indeksu, omogućuju usporedbu prognostičke snage indeksa. Slijede prilagodbe složenijih mjera kojima se procjenjuje kvaliteta prognostičkih sustava i njihovih indeksa obuhvaćenih matricom vrednovanja prognostičkih pokazatelja. Prognostička se snaga ocjenjuje i dvama regresijskim modelima, koji dodatno omogućuju prognoziranje referentne serije i daju ocjenu prognoze. Rezultati mjera prognostičke moći usuglašeno upućuju na to da izvorni CROLEI indeks ima najveću prognostičku snagu te da s najvećom vjerojatnošću navješćuje zaokret u gospodarskoj aktivnosti.

Ključne riječi: CROLEI, prognostički pokazatelj, barometarska metoda, signalna metoda.

* Autorice zahvaljuju Danijelu Nestiću i Andreji Mervar, kolegama iz Ekonomskog instituta u Zagrebu, na korisnim savjetima prilikom izrade rada, kao i anonimnim recenzentima na komentarima na osnovi kojih je rad poboljšan.

** Primljeno (*Received*): 6.6.2006.
Prihvaćeno (*Accepted*): 28.11.2006.

Uvod

CROLEI (engl. *Croatian Leading Economic Indicators*) kompozitni je prognostički indeks izgrađen od jedanaest pokazatelja koji mu prethode i navještaju smjer kretanja hrvatskoga gospodarstva do šest mjeseci unaprijed (Ahec-Šonje i sur., 1994; 1996; Ahec-Šonje, 1995). CROLEI je 1995. postao prva mjera predviđanja kretanja domaće ekonomske aktivnosti izgrađena na osnovi *barometarske* metode National Bureau of Economic Research (NBER) (USDC i BEA, 1977; Zarnowitz i Boschan, 1975; Gapinski, 1982; Shiskin, 1961; Moore i Shiskin, 1967). Barometarska se metoda zasniva na pristupu prethodećih pokazatelja, a koraci su u metodi izgradnja baze podataka i tehnika kojima se prate, nadgledaju, najavljuju i potvrđuju cikličke promjene u gospodarstvu. Danas se kretanje CROLEI indeksa objavljuje mjesečno da bi se pravodobno predvidjelo kretanje ukupnoga gospodarstva, a upravo je mogućnost mjesečnoga izračuna indeksa jedna od najvećih prednosti primjene barometarske metode. Kretanje gospodarske aktivnosti u Hrvatskoj aproksimirano je uz pomoć sezonski prilagođene serije *opsega industrijske proizvodnje*, koja se u metodi naziva referentom serijom.

Zadatak ovoga rada jest konstruirati alternativne prognostičke indekse na osnovi barometarske metode, koristeći se pritom različitim transformacijama vremenskih serija iz CROLEI baze (v. dodatak 1). Na taj se način želi utvrditi utječu li transformacije vremenskih serija značajno na rezultate Grangerova testa uzročnosti, koji su poslije jedan od osnovnih kriterija za uvrštenje prethodećih pokazatelja u kompozitni prognostički indeks. Taj metodološki korak želimo ispitati stoga što je primjena Grangerova testa uzročnosti metodološka inovacija u primjeni barometarske metode u Hrvatskoj. Krajnji je cilj ispitivanja sustava utvrditi hoće li prognostički indeksi zasnovani na različitim transformacijama vremenskih serija, i stoga izgrađeni od drukčijih pokazatelja, omogućiti bolju prognozu ekonomske aktivnosti od izvornoga CROLEI indeksa.

Rad se sastoji od tri cjeline. Nakon uvoda, u kojemu se detaljno objašnjava prilagodba u primjeni barometarske metode kao osnovni uzrok propitivanja CROLEI sustava, slijedi empirijski dio rada. On počinje testiranjem potencijalnih pokazatelja kao originalnih serija; desezoniranih serija; desezoniranih i logaritmiranih serija te desezoniranih serija u prvim diferencijama, uz pomoć Grangerova testa uzročnosti. Rezultat su liste različitih potencijalnih pokazatelja kao potencijalnih elemenata za ulazak u izvorni CROLEI sustav i sustave alternativnih CROLEI indeksa. Autori zatim ocjenjuju prognostička obilježja svih potencijalnih pokazatelja iz listi pokazatelja prema metodi ocjenjivanja koja je sastavnica barometarske metode. Na osnovi ocjena pokazatelja odabiru se pokazatelji u alternativnim prognostičkim indeksima. Prva cjelina rada završava izgradnjom alternativnih prognostičkih indeksa prema NBER algoritmu i prikazom njihova kretanja. U drugoj cjelini slijedi vrednovanje prognostičke snage izvornoga CROLEI indeksa i alternativnih indeksa uz pomoć prilagođene matrice vrednovanja preuzete iz signalne metode. Osim tog pokušaja vrednovanja indeksa, autorice ocjenjuju indekse uz pomoć ocjene dvaju regresijskih modela koji se rabe za prognoziranje referentne serije unutar uzorka. U trećoj, posljednjoj cjelini rada autorice se osvrću na pojavu novoga prognostičkog sustava (Cerovac, 2005). Naposljetku slijedi zaključak rada.

1. Ima li smisla mijenjati nešto što dobro funkcionira?

CROLEI se sustav nakon revizije 2004. godine, što je metodološki postupak kojim se svakih nekoliko godina primjenom barometarske metode nastoji poboljšati kvaliteta prognostičkoga sustava, sastoji od jedanaest komponenti koje potječu iz četiri sektora gospodarstva – realnoga, monetarnoga, međunarodnoga i fiskalnoga. Kretanje komponenti predviđa kretanje ukupne gospodarske aktivnosti aproksimirane industrijskom proizvodnjom do šest mjeseci unaprijed. Tijekom posljednje revizije 2004. istraživački je tim utvrdio da je CROLEI pravodobno navijestio četiri točke zaokreta u kretanju referentne serije u razdoblju 1995-2004. (Bačić i sur., 2004:12). Budući da CROLEI sustav uspješno predviđa točke zaokreta i da je nastao kao rezultat metode koja se primjenjuje u svijetu, postavlja se pitanje ima li smisla mijenjati nešto što dobro funkcionira.

Stoga potreba za ispitivanjem i vrednovanjem ne proistječe iz same barometarske metode, već iz prilagodbe metode načinjene u jednom metodološkom koraku, kada je prvi put primijenjena u Hrvatskoj. Riječ je o uvođenju Grangerova testa uzročnosti za dvije slučajne varijable, rezultate kojega je autorica Ahec-Šonje (1995) i Ahec-Šonje i sur. (1994; 1996) uvela kao zamjenske kriterije za dva kriterija iz originalne metode pri ocjenjivanju prognostičke snage potencijalnih komponenti ili tzv. *ocjenjivanju* (Moore i Shiskin, 1967:22-28). U barometarskoj se metodi unutar postupka ocjenjivanja, među ostalima, kao dva kriterija za ocjenjivanje navode *usuglašenost kretanja s poslovnim ciklusom* i *konzistentnost u prethođenju*. Unutar kriterija *usuglašenost kretanja s poslovnim ciklusom* ocjenjuju se: a) vjerojatnost da se pokazatelj slučajno ciklički usuglašeno kreće s poslovnim ciklusom; b) izostanak zaokreta u seriji pokazatelja kada postoji zaokret u poslovnom ciklusu; c) izostanak nedavnih grešaka u usuglašenosti; d) jasnoća cikličkog kretanja serije. Unutar kriterija *konzistentnost u prethođenju* ocjenjuje se konzistentnost u vremenu prethođenja/zaostajanja pokazatelja s obzirom na točke zaokreta u poslovnom ciklusu. Oba kriterija zajedno čine 40% ukupne ocjene jednoga pokazatelja. Dok je prema Ahec-Šonje i sur. (1994:29) stupanj *usuglašenosti kretanja potencijalnog pokazatelja s poslovnim ciklusom* moguće mjeriti uz pomoć *indeksa usuglašenosti*, koji je neka vrsta korelacijskog koeficijenta, *konzistentnost pokazatelja u prethođenju, praćenju ili zaostajanju* za stvarnim pojavama nešto je složenija. Za primjenu tih kriterija ocjenjivanja potrebno je imati dostatan broj zaokreta i dulje vremenske serije. Radi ilustracije, u SAD su se 1990-ih, u tijeku revizija njihova prognostičkog sustava, revidirale serije koje započinju čak godine 1948. (Green, 1993), dok je početak serija u posljednjoj reviziji CROLEI-ja tek 1995. godina.

Autorica i njezin istraživački tim u studiji u kojoj izlažu metodološki okvir za izradu sustava prethodećih pokazatelja napominju da se izvorni sustav ocjenjivanja u literaturi temelji više na vrijednosnim sudovima istraživačkoga tima nego na sofisticiranim empirijskim analizama (Ahec-Šonje i sur., 1994). Stoga je uvođenje rezultata Grangerova testa uzročnosti kao egzaktnog kriterija za ocjenjivanje serija kreativna i kvalitetna prilagodba barometarske metode u njezinoj primjeni u Hrvatskoj, koja je kasnije na sličan način primijenjena i u Sloveniji (Jagrič, 2001; Jagrič, Boršič i Strašek, 2003). Osim toga, takva modifikacija, iako opravdana stanjem statističke podloge i gospodarskih okolnosti u Hrvatskoj, zahtijeva empirijsku verifikaciju.

Dakle, modifikacija u primjeni metode u Hrvatskoj zasniva se na proširenoj upotrebi rezultata Grangerova testa uzročnosti (Granger, 1969, 1988). Osnovna je prednost upotrebe Grangerova testa uzročnosti to što on daje nekoliko informacija o odnosu dviju slučajnih varijabli, X i Y. Prvo, može se utvrditi objašnjava li vremenski-unatrag-pomaknuti Y kretanje X, kao i to objašnjava li istodobno vremenski-unatrag-pomaknuti X kretanje Y. Drugo, možemo otkriti na kojem vremenskom pomaku postoji veza. Kao posljednje, ako se test postavi kao regresijska jednadžba, on daje ukupnu ocjenu regresije i predznak koeficijenta uz objašnjavajuću varijablu. Sva se četiri elementa mogu upotrebljavati pri ocjenjivanju serija. Izraz Grangerova testa za opisane varijable jest:

$$Y_t = c_1 + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{i=1}^p \beta_i X_{t-i} + u_t \quad (1)$$

gdje t označuje tijek vremena koje ide od 0 do 12, a c_1 , α_i i β_i parametri su koje treba ocijeniti. Odabir broja vremenskih pomaka posljedica je subjektivne procjene istraživača i uvriježenoga istraživačkog pravila.

Prema Ashely, Granger i Schmalensee (1980), nedostatak testa je njegova osjetljivost na transformaciju vremenskih serija. U CROLEI sustavu pri testiranju Grangerovim testom korištene su desezonirane serije potencijalnih pokazatelja, kao i desezonirana referentna serija, tj. desezonirani opseg industrijske proizvodnje. Uz pomoć Grangerova testa testirani su i trend-ciklusi potencijalnih pokazatelja i industrijske proizvodnje. Takav je pristup osigurao visok broj potencijalnih pokazatelja i informacija o njihovoj prognostičkoj kvaliteti, kao i visok broj potencijalnih serija – kandidata za postupak ocjenjivanja.

No primjenom različitih transformacija vremenskih serija moguće je dobiti različite rezultate Grangerova testa (Granger, Huang i Yang, 2000; Sander i Kleimeier, 2003; Rousseau i Vuthipadorn, 2005). Kako se dosad nisu testirali transformirani potencijalni pokazatelji, to kanimo učiniti u ovome radu. Ako rezultati budu značajno različiti od postojećih, to bi moglo rezultirati sasvim novim CROLEI indeksom. Hoće li alternativni indeksi biti bolji od postojećega, pokušat ćemo utvrditi uz pomoć složenih mjera prognostičke snage iz literature ekonomske prognostike, koje je za ovu svrhu bilo potrebno prilagoditi.

1.1. Rezultati testova uzročnosti na transformiranim vremenskim serijama

Na samome početku ispitivanja CROLEI sustava potencijalni su pokazatelji iz baze podataka u slučajevima, kad je to bilo potrebno, deflacionirani¹, a zatim su svi potencijalni pokazatelji desezonirani. Potom je primijenjena *grafička* metoda, koja je obuhvatila grafički prikaz potencijalnog pokazatelja i referentne serije na osnovi njihove desezonirane komponente i na osnovi njihove trend-ciklus komponente. Na temelju zapažanja svi su potencijalni pokazatelji iz CROLEI baze podataka razvrstani u skupine pratećih, na-

¹ Pritom je korišteno više deflatora, i to u izvornome i u izvedenom obliku. Riječ je o deflatoru na osnovi indeksa potrošačkih cijena i o deflatoru na osnovi indeksa cijena pri proizvođačima, od kojih je sastavljen novi, složeni deflator. Uz to, sastavljeni su deflatori na osnovi tečaja USD i EUR, a zatim su na osnovi njih i valutne strukture robne razmjene izgrađeni kompozitni deflatori robnog uvoza i izvoza.

vješćućih i zaostajućih pokazatelja (Bačić i sur., 2004) ili u skupinu neznačajnih pokazatelja. Time se sužuje izbor navješćućih potencijalnih pokazatelja na njih 69.

Kako literatura o Grangerovu testu uzročnosti govori da rezultati mogu znatno varirati ovisno o tome na koji se način transformiraju vremenske serije, potencijalni će se pokazatelji testirati na tri različito transformirana skupa serija: a) na serijama koje nisu transformirane, tj. na originalnim serijama; b) na serijama u diferencijama – ovisno o rezultatima testa na stacionarnost i c) na logaritmiranim serijama. Pritom treba napomenuti da je referentna serija – opseg industrijske proizvodnje, transformirana na isti način kao i potencijalni pokazatelji.

Kriteriji za ulazak na listu potencijalnih pokazatelja isti su za sva tri skupa serija i primijenjeni su pri ocjenjivanju serija Grangerovim testom u reviziji CROLEI-ja 2004. godine. To su: a) p-vrijednost ispod razine 0,05; b) visoka ocjena regresijske jednadžbe (R^2) i c) t-statistika iznad ili blizu $|2,00|$. Grangerov je test proveden za razdoblje siječanj 1995. – travanj 2004. Poštujući navedene kriterije dobili smo listu potencijalnih pokazatelja za izvorni sustav i za alternativne prognostičke sustave (tabl. 1).

Tablica 1. Lista potencijalnih pokazatelja

a) Desezonirane serije – postojeći CROLEI prema reviziji iz 2004.

| | |
|------|--|
| S 43 | Nominalna neto plaća po zaposlenome |
| S 48 | Zaposleni s evidencije tijekom mjeseca |
| S 51 | Korisnici novčane naknade |
| S 54 | Broj noćenja turista |
| S 55 | Broj noćenja stranih turista |
| S 58 | Promet u trgovini na malo, realni |
| S 76 | Izvoz kemijskih proizvoda |
| S 92 | Uvoz strojeva i transportnih uređaja |
| S 95 | Nekonsolidirani prihod državnog proračuna |
| S105 | Novčana masa M1 |
| S106 | Novčana masa M1a |
| S107 | Ukupna likvidna sredstva |
| S109 | Gotov novac |
| S113 | Štedni i oročeni depoziti u poslovnim bankama, devizni |
| S114 | Štedni i oročeni depoziti u poslovnim bankama, devizni, stanovništvo |
| S115 | Štedni i oročeni depoziti u poslovnim bankama, devizni, poduzeća |
| S116 | Plasmani |
| S123 | Devizne rezerve poslovnih banaka, oročeni depoziti s otkaznim rokom |
| S136 | Kamatna stopa na tržištu novca, dnevno tržište |
| S146 | Porezni prihodi, porez na promet proizvoda i usluga |
| S155 | Prihodi, trošarina na motorna vozila |
| S157 | Prihodi državnog proračuna, ukupno |
| S112 | Štedni i oročeni depoziti u poslovnim bankama, kunski |
| S164 | Rashodi, kapitalni izdaci |
| S165 | Suficit/deficit državnog proračuna |

b) Originalne serije

- S 02 Indeks fizičkog opsega industrijske proizvodnje – rudarstvo i vađenje
 - S 33 Indeks fizičkog opsega industrijske proizvodnje – proizvodnja ostalih prijevoznih sredstava
 - S 43 Nominalna neto plaća po zaposlenome
 - S 52 Osobe nezaposlene zbog prestanka rada poduzeća ili poslodavca
 - S 56 Broj noćenja domaćih turista
 - S 72 Izvoz pića i duhana
 - S 85 Uvoz hrane i živih životinja
 - S 90 Uvoz kemijskih proizvoda
 - S 91 Uvoz proizvoda, raznih gotovih
 - S121 Devizne rezerve poslovnih banaka, ukupno
 - S137 Kamatna stopa na tržištu novca
 - S140 Prihodi državnog proračuna, ukupno
 - S143 Porezni prihod, ukupno
 - S144 Porezni prihod, porez na dobit
 - S164 Rashodi, kapitalni izdaci
-

c) Serije u diferencijama prema rezultatima testova jediničnih korijena^a

- S 05 Indeks fizičkog opsega industrijske proizvodnje, energija
 - S 06 Indeks fizičkog opsega industrijske proizvodnje, intermedijarni proizvodi, osim energije
 - S 20 Indeks fizičkog opsega industrijske proizvodnje, izdavačka i tiskarska djelatnost
 - S 24 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja ostalih nemetalnih mineralnih proizvoda
 - S 43r Nominalna neto plaća po zaposlenome, ukupno
 - S 47 Osobe koje prvi put traže zaposlenje prema stanju krajem mjeseca
 - S 54 Broj noćenja turista, ukupno
 - S 86r Uvoz pića i duhana
 - S 94r Uvoz proizvoda i transakcije, nespomenuti
 - S109r Gotov novac
 - S120r Inozemna aktiva HNB-a
 - S122r Devizne rezerve poslovnih banaka, tekući računi i depoziti po deviznoj štednji
 - S123r Devizne rezerve poslovnih banaka, oročeni depoziti i depoziti s otkaznim rokom
 - S146 Porezni prihod, porez na promet proizvoda i usluga
 - S148r Porezni prihod, carine, carinske i uvozne pristojbe
 - S157r Rashodi državnog proračuna, ukupno
 - S159r Rashodi, bruto plaće službenika i namještenika
-

d) Logaritmirane serije

- S 03 Indeks fizičkog opsega industrijske proizvodnje, prerađivačka industrija
 - S 09 Indeks fizičkog opsega industrijske proizvodnje, netrajni proizvodi za široku potrošnju
 - S 11 Indeks fizičkog opsega industrijske proizvodnje, vađenje sirove nafte i zemnog plina; uslužne djelatnosti
 - S 13 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja hrane i pića
 - S 24 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja ostalih nemetalnih mineralnih proizvoda
-

| | |
|-------|--|
| S 49 | Prijavljene potrebe za radnicima tijekom mjeseca |
| S 67r | Izvoz roba, ukupno |
| S 71r | Izvoz hrane i živih životinja |
| S 74r | Izvoz mineralnih goriva i maziva |
| S 75r | Izvoz životinjskih i biljnih ulja i masti |
| S 79r | Izvoz raznih gotovih proizvoda |
| S 81r | Uvoz roba, ukupno |
| S105r | Novčana masa M1 |
| S118r | Krediti poduzećima |
| S122r | Devizne rezerve poslovnih banaka, tekući računi i depoziti po deviznoj štednji |
| S129 | Kamatna stopa HNB-a na lombardne kredite |
| S140r | Prihodi državnog proračuna, ukupno |
| S148r | Porezni prihod, carine, carinske i uvozne pristojbe |
| S149r | Prihodi od trošarina, ukupno |
| S150r | Prihodi, trošarine na naftne derivate |
| S162r | Rashodi, tekući transferi |

^a*Napomena: korišteni su prošireni Dickey-Fullerov test i Phillips-Peronov test, s tim da je optimalni broj vremenskih pomaka određen uz pomoć Schwartz informacijskog kriterija; rezultati testova jediničnih korijena mogu se na upit dobiti od autorica.*

Izvor: za a) Bačić i sur. (2004); za b),c) i d) izračun autorica

Rezultati Grangerova testa uzročnosti (prema jednadžbi 1) za potencijalne pokazatelje i opseg industrijske proizvodnje potvrdili su nalaze empirijske literature o tome kako su rezultati testa osjetljivi na transformaciju serija.² Svaki je skup testiranja rezultirao listom potencijalnih pokazatelja sasvim različitom od ostalih skupova testiranja. Liste potencijalnih pokazatelja podudaraju se u samo jednoj ili dvije serije. Najveći je broj potencijalnih pokazatelja, osim CROLEI-ja nastaloga revizijom 2004, dao skup testiranja na logaritmiranim vremenskim serijama. Takav rezultat ne iznenađuje jer su u tom setu serije sasvim “izgladene”, pa je veća i vjerojatnost da se ustanovi uzročnost iz smjera potencijalnog pokazatelja prema referentnoj seriji. To, kao i činjenica da je velika većina serija integrirana reda I(1), objašnjava i visoke ocjene regresijske jednadžbe³ u posljednjem skupu testiranja, za razliku od ostalih skupova testiranja, u kojima su te ocjene znatno niže, osim izvornog CROLEI-ja.

1.2. Ocjenjivanje potencijalnih pokazatelja

Ocjenjivanje serija postupak je koji slijedi nakon identificiranja potencijalnih pokazatelja, a riječ je o dodjeljivanju ocjena svakoj pojedinačnoj seriji prema kriterijima *ekonomske značajnosti, statističke značajnosti, konzistentnosti u prethođenju, “izgladenosti”*

² Cilj je testa utvrditi postoji li uzročnost između potencijalnog pokazatelja i referentne serije. Slijedeći taj pristup, pretpostavljamo da postoje dodatne objašnjavajuće varijable koje nisu uključene u model, a utjecaj kojih se može očitovati u rezidualima. Stoga rezultate dijagnostičkih testova reziduala nismo razmatrali.

³ Rezultati Grangerova testa uzročnosti mogu se dobiti od autorica na upit.

serije i ažurnosti statističke podloge. Pošto se dodijele ocjene prema navedenim kriterijima, one se važu (ponderiraju) i potom zbrajaju u konačnu ocjenu serije koja može iznositi najviše 100. Koji će se ponder dodijeliti pojedinom kriteriju, ovisi o procjeni istraživačkoga tima (Ahec-Šonje i sur., 1994), ali je vidljivo da je odabir pondera za hrvatsko gospodarstvo vrlo blizak izboru NBER (v. Zarnowitz, 1992). Treba istaknuti da se autorice ovoga rada pri ocjenjivanju koriste istim kriterijima koji su korišteni u reviziji 2004. godine kako bi mogle usporediti izvorni s alternativnim CROLEI sustavima.

Nabrojanih se pet kriterija može dodatno objasniti.

- *Ekonomskom se značajnošću* određuje je li serija agregat (npr. serija *noćenja turista*), podagregat (npr. serija *noćenja stranih turista*) ili usko definirani pokazatelj (npr. serija *noćenja turista iz Austrije*). Kako su agregati poželjniji od podagregata, oni dobivaju i višu ocjenu.
- *Statistička značajnost* odnosi se na kvalitetu statističkoga praćenje serije, pa su poželjnije serije koje se prate kao cijela populacija, serije u kojima nema promjena u metodologiji praćenja itd. *Konzistentnost u prethođenju* odnosi se na jakost veze potencijalnog pokazatelja i referentne serije. Pritom koeficijent determinacije ili R^2 (koji se dobiva iz Grangerova testa) služi kao mjera jakosti veze, pa je poželjno da je on što viši kako bi ocjena bila viša.
- *Izgladañnost serije* odnosi se na predvidivost njezina kretanja. Naime, poželjnije su serije kojima dominira ciklička komponenta od serija kojima dominira iregularna komponenta. Za ocjenjivanje serije prema tom kriteriju primjenjuje se mjera proizašla iz postupka desezoniranja, a riječ je o broju mjeseci u kojima prosječna postotna promjena cikličke komponente premašuje prosječnu postotnu promjenu iregularne komponente MCD (engl. *months-for-cyclical-dominance*) (Bačić i sur., 2004:19).
- *Ažurnost statističke podloge* označava redovitost i točnost statističkoga izvještavanja. S obzirom na potrebu da se indeks izračunava na mjesečnoj osnovi, svi podaci potrebni za izračun indeksa moraju biti dostupni do određenoga datuma u mjesecu. Stoga serije u kojima postoje kašnjenja u objavljivanju dobivaju niže ocjene.

Kriterij *konzistentnost u prethođenju* ima najviši ponder u konačnoj ocjeni (30%), dok *ažurnost statističke podloge* ima najniži (10%). Ključni je kriterij pri izboru pokazatelja *ekonomska značajnost serije* (Bačić i sur., 2004:15). Također je poželjno da potencijalni pokazatelj ima što dulje vrijeme prethođenja referentnoj seriji, pa su pri ocjenjivanju izostavljeni pokazatelji čije je vrijeme prethođenja kraće od 4 mjeseca. Ocjene pokazatelja u alternativnim modelima CROLEI-ja te ocjene izvornoga CROLEI-ja iz revizije 2004. prikazani su u tablici 2.

Tablica 2. Potencijalni pokazatelji rangirani prema ukupnoj ocjeni

| a) Desezonirane serije (D11) – izvorni CROLEI prema reviziji iz 2004. | | Konačna ocjena |
|---|---|----------------|
| S136 | Kamatna stopa na tržištu novca, dnevno tržište | 92 |
| S112 | Štedni i oročeni depoziti u poslovnim bankama, kunski | 92 |
| S109 | Gotov novac | 92 |

| | | |
|------|--|----|
| S 48 | Zaposleni s evidencije tijekom mjeseca | 88 |
| S123 | Devizne rezerve poslovnih banaka, oročeni depoziti, depozit s otkaznim rokom | 88 |
| S 43 | Nominalna neto plaća po zaposlenome | 87 |
| S 58 | Promet u trgovini na malo, realni | 87 |
| S 54 | Broj noćenja turista | 84 |
| S 55 | Broj noćenja stranih turista | 80 |
| S 51 | Korisnici novčane naknade | 79 |
| S 95 | Nekonsolidirani prihod državnog proračuna | 75 |
| S107 | Ukupna likvidna sredstva | 75 |
| S116 | Plasmani | 75 |
| S105 | Novčana masa M1 | 71 |
| S106 | Novčana masa M1a | 71 |
| S113 | Štedni i oročeni depoziti u poslovnim bankama, devizni | 71 |
| S114 | Štedni i oročeni depoziti u poslovnim bankama, devizni, stanovništvo | 67 |
| S 92 | Uvoz strojeva i transportnih uređaja | 66 |
| S115 | Štedni i oročeni depoziti u poslovnim bankama, devizni, poduzeća | 63 |
| S157 | Prihodi državnog proračuna, ukupno | 55 |
| S165 | Suficit/deficit državnog proračuna | 55 |
| S164 | Rashodi, kapitalni izdaci | 51 |
| S 76 | Izvoz kemijskih proizvoda | 48 |
| S155 | Prihodi, trošarina na motorna vozila | 48 |
| S146 | Porezni prihodi, porez na promet proizvoda i usluga | 46 |

Izvor: Bačić i sur. (2004).

| b) Originalne serije (A1) | | Konačna ocjena |
|---------------------------|---|----------------|
| S121 | Devizne rezerve poslovnih banaka, ukupno | 83 |
| S137 | Kamatna stopa na tržištu novca | 79 |
| S 43 | Nominalna neto plaća po zaposlenome | 78 |
| S 52 | Osobe nezaposlene zbog prestanka rada poduzeća ili poslodavca | 75 |
| S143 | Porezni prihod, ukupno | 66 |
| S 33 | Indeks fizičkog opsega industrijske proizvodnje – proizvodnja ostalih prijevoznih sredstava | 63 |
| S 91 | Uvoz proizvoda, raznih gotovih | 58 |
| S 02 | Indeks fizičkog opsega industrijske proizvodnje – rudarstvo i vađenje | 55 |
| S 90 | Uvoz kemijskih proizvoda | 54 |
| S140 | Prihodi državnog proračuna, ukupno | 54 |
| S 56 | Broj noćenja domaćih turista | 51 |
| S164 | Rashodi, kapitalni izdaci | 51 |
| S144 | Porezni prihod, porez na dobit | 51 |
| S 85 | Uvoz hrane i živih životinja | 46 |
| S 72 | Izvoz pića i duhana | 37 |

Izvor: izračun autorica

| c) Serije u diferencijama prema rezultatima testa stacionarnosti | Konačna ocjena |
|---|----------------|
| S 47 Osobe koje prvi put traže zaposlenje prema stanju krajem mjeseca | 66 |
| S 24 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja ostalih nemetalnih mineralnih proizvoda | 62 |
| S109r Gotov novac | 62 |
| S120r Inozemna aktiva HNB-a | 62 |
| S123r Devizne rezerve poslovnih banaka, oročeni depoziti i depoziti s otkaznim rokom | 58 |
| S 43r Nominalna neto plaća po zaposlenome, ukupno | 57 |
| S 20 Indeks fizičkog opsega industrijske proizvodnje, izdavačka i tiskarska djelatnost | 54 |
| S 54 Broj noćenja turista, ukupno | 54 |
| S 05 Indeks fizičkog opsega industrijske proizvodnje, energija | 50 |
| S 06 Indeks fizičkog opsega industrijske proizvodnje, intermedijarni proizvodi, osim energije | 50 |
| S122r Devizne rezerve poslovnih banaka, tekući računi i depoziti po deviznoj štednji | 50 |
| S159r Rashodi, bruto plaće službenika i namještenika | 49 |
| S157r Rashodi državnog proračuna, ukupno | 46 |
| S 86r Uvoz pića i duhana | 37 |
| S 94r Uvoz proizvoda i transakcije, nespomenuti | 37 |
| S146 Porezni prihod, porez na promet proizvoda i usluga | 37 |
| S148r Porezni prihod, carine, carinske i uvozne pristojbe | 37 |

Izvor: izračun autorica

| d) Logaritmirane serije | Konačna ocjena |
|--|----------------|
| S 49 Prijavljene potrebe za radnicima tijekom mjeseca | 86 |
| S105r Novčana masa M1 | 86 |
| S118r Krediti poduzećima | 85 |
| S129 Kamatna stopa HNB-a na lombardne kredite | 81 |
| S 24 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja ostalih nemetalnih mineralnih proizvoda | 74 |
| S122r Devizne rezerve poslovnih banaka, tekući računi i depoziti po deviznoj štednji | 74 |
| S162r Rashodi, tekući transferi | 74 |
| S 03 Indeks fizičkog opsega industrijske proizvodnje, prerađivačka industrija | 73 |
| S 13 Indeks fizičkog opsega industrijske proizvodnje, proizvodnja hrane i pića | 73 |
| S140r Prihodi državnog proračuna, ukupno | 72 |
| S 09 Indeks fizičkog opsega industrijske proizvodnje, netrajni proizvodi za široku potrošnju | 71 |
| S 11 Indeks fizičkog opsega industrijske proizvodnje, vađenje sirove nafte i zemnog plina; uslužne djelatnosti | 70 |
| S 67r Izvoz robe, ukupno | 68 |
| S 81r Uvoz robe, ukupno | 66 |
| S149r Prihodi, trošarine ukupno | 66 |

| | | |
|-------|---|----|
| S 71r | Izvoz hrane i živih životinja | 64 |
| S 74r | Izvoz mineralnih goriva i maziva | 64 |
| S150r | Prihodi, trošarine na naftne derivate | 62 |
| S 79r | Izvoz raznih gotovih proizvoda | 61 |
| S148r | Porezni prihod, carine, carinske i uvozne pristojbe | 61 |
| S 75r | Izvoz životinjskih i biljnih ulja i masti | 58 |

Izvor: izračun autorica

Iz tablice 2, u kojoj su prikazane ocjene svih pokazatelja po pojedinim sustavima, vidljivo je da su najviše ocjene dobile serije u izvornome CROLEI sustavu, potom slijede logaritmizirane serije i serije koje nisu tretirane. Serije u diferencijama dobile su najlošije ocjene zbog niskih koeficijenata determinacije, što je bilo i očekivano jer se, ako je većina serija I(1), ocjenom Grangerova testa nad diferenciranim podacima nužno dobiva niži koeficijent determinacije. No usporedba ocijenjenih pokazatelja među sustavima nije toliko značajna koliko su značajna individualna obilježja pokazatelja koji su se našli na listama četiriju sustava.

Usporedbom rezultata CROLEI sustava na osnovi originalnih serija s izvornim CROLEI sustavom može se uočiti da u alternativnome sustavu ima više serija podagregata nego u izvornome CROLEI-ju. Slično je i u ostalim alternativnim sustavima. U sustavu s originalnim serijama ocjene su niže zbog izostanka transformacije serija. Izvorni je CROLEI sustav ipak prošao postupak desezoniranja koji obuhvaća uprosječivanje metodom pomičnih prosjeka, zbog čega su serije “izgladenije” od originala.

U sustavu sa serijama u diferencijama prema rezultatima testa stacionarnosti u postupak ocjenjivanja ušlo je više serija nego u sustavu s originalnim serijama. Niže su ocjene ponajprije rezultat niskog koeficijenta determinacije nastalog diferenciranjem nestacionarnih serija, čime je eliminirana deterministička trend-komponenta i problem tzv. lažne regresije. Nasuprot tome, zahvaljujući visokim koeficijentima determinacije, sustav s logaritmiziranim serijama dobio je više konačne ocjene potencijalnih pokazatelja. Zanimljivo je da u tom sustavu prvi put ne sudjeluje serija “nominalna neto plaća po zaposlenome”, koja se može pronaći u svim ostalim sustavima.

1.3. Odabir elemenata prognostičkih sustava

Iz ocjenjivanja serija vidljivo je koji su pokazatelji u prognostičkome sustavu poželjniji, što je i omogućilo da se potencijalni pokazatelji rangiraju prema njihovoj konačnoj ocjeni. No kako slijedi odabir elemenata prognostičkoga sustava, koji će u konačnici biti sastavni dio prognostičkoga iskaza, postavlja se pitanje koji bi pokazatelji s liste trebali ući u indeks. Dakako, logično je da to budu pokazatelji sa što višom konačnom ocjenom. Ali moguće je da najviše konačne ocjene u jednom sustavu dobiju isključivo serije iz npr. monetarnog sektora. U tom se slučaju u sustav ne mogu uključiti sve te serije. Optimalan bi izbor bio da u sustavu jednako budu zastupljene serije iz svih sektora gospodarstva. Prema Bačić i sur. (2004:26), u reviziji 2004. vrijedili su ovi kriteriji:

- zanemariva iregularna komponenta u kretanju serije
- visoke konačne ocjene, pri čemu se kao donja granica za izbor uzima ocjena 70
- dovoljno dugo vrijeme prethođenja potencijalnog pokazatelja referentnoj seriji
- prioritet ekonomskih agregata pri izboru.

Poštujući navedene kriterije, u 2004. odabrano je jedanaest serija – komponenti CROLEI sustava: nominalna neto plaća po zaposlenome, zaposleni s evidencije tijekom mjeseca, noćenja turista, realni promet u trgovini na malo, uvoz strojeva i transportnih uređaja, nekonsolidirani prihodi proračuna, ukupna likvidna sredstva, gotov novac, štedni i oročeni kunski depoziti poslovnih banaka, devizne rezerve poslovnih banaka na oročene depozite s otkaznim rokom i kamatna stopa na dnevnom tržištu novca (tabl. 3). Iznimka je serija *uvoz strojeva i transportnih uređaja*, koja ima konačnu ocjenu nižu od 70, ali ulazi u indeks zbog visoke ocjene ekonomske utemeljenosti. Osim što su njime poštovani kriteriji za ulazak u sustav CROLEI, taj je odabir komponenti optimalan jer su uključene serije iz četiri sektora gospodarstva. Treba napomenuti da to nije uvijek moguće jer serije iz pojedinih sektora gospodarstva ne moraju bezuvjetno biti dobri prethodeći pokazatelji. No izostanak nekog od sektora u prognostičkome sustavu ne znači da je konačni prognostički iskaz manje kvalitetan.

Nažalost, kriteriji iz revizije 2004. ne mogu se u potpunosti primijeniti pri izboru elemenata alternativnih prognostičkih sustava. Osnovni je razlog prevladavajuća niža razina konačnih ocjena potencijalnih pokazatelja, kao i općenito niži broj serija koje su prošle Grangerov test i zatim bile ocjenjivane. Zbog toga se odabir serija – potencijalnih pokazatelja mora provoditi po jednostavnijim kriterijima i zbog manjeg broja serija gotovo se nameće sam po sebi. Dakle, u alternativne sustave ulaze serije s višim konačnim ocjenama, i to tako da, koliko je moguće, budu zastupljena sva četiri sektora gospodarstva.

U tablicama 3-6. prikazani su odabrani pokazatelji na osnovi kojih će se konstruirati alternativni indeksi. Od tri alternativna sustava, prva dva (tabl. 4. i 5) imaju jedanaest komponenti, dok posljednji ima devet komponenti (tabl. 6). Kako u literaturi ne postoji pravilo prema kojemu je određen nužan broj komponenti, nešto niži broj komponenti u posljednjem alternativnom modelu nije zapreka za daljnju izgradnju prognostičkoga sustava. U tablicama su također prikazani elementi koji su potrebni za daljnji razvoj sustava: prosječno vrijeme prethođenja referentnoj seriji i konačne ocjene po komponentama (S_i) uz pomoć kojih se dobivaju ponderi značajnosti (W_i). Dobiveni će ponderi značajnosti pri izračunu indeksa poslužiti kao mjera sudjelovanja komponenti u sustavu s obzirom na druge komponente sustava.

Tablica 3. Izvorni CROLEI indeks iz 2004.

| Serija | Vrijeme prethođenja | Ukupna ocjena (S_i) | Ponder (W_i) |
|--------|---------------------|-------------------------|------------------|
| S 43 | -4 | 87 | 1,03 |
| S 48 | -4 | 88 | 1,05 |
| S 54 | -9 | 84 | 1,00 |
| S 58 | -8 | 87 | 1,03 |
| S 92 | -8 | 66 | 0,78 |
| S 95 | -4 | 75 | 0,89 |
| S107 | -4 | 75 | 0,89 |

| | | | |
|----------|------|------|-------|
| S109 | -5 | 92 | 1,09 |
| S112 | -4 | 92 | 1,09 |
| S123 | -8 | 88 | 1,05 |
| S136 | -5 | 92 | 1,09 |
| ukupno | | 926 | 11,00 |
| prosjeak | -5,7 | 84,2 | |

Izvor: Bačić i sur. (2004)

Tablica 4. CROLEI na osnovi originalnih komponenti

| Seriya | Vrijeme prethođenja | Ukupna ocjena (Si) | Ponder (Wi) |
|----------|---------------------|--------------------|-------------|
| S 02 | -11 | 55 | 0,85 |
| S 33 | -11 | 63 | 0,97 |
| S 43 | -12 | 78 | 1,20 |
| S 52 | -6 | 75 | 1,16 |
| S 56 | -11 | 51 | 0,79 |
| S 90 | -11 | 54 | 0,83 |
| S 91 | -12 | 58 | 0,89 |
| S121 | -12 | 83 | 1,28 |
| S137 | -12 | 79 | 1,22 |
| S143 | -12 | 66 | 1,02 |
| S164 | -6 | 51 | 0,79 |
| ukupno | | 713 | 11,00 |
| prosjeak | -10,6 | 64,8 | |

Izvor: izračun autorica

Tablica 5. CROLEI indeks na osnovi serija u diferencijama prema rezultatima testa stacionarnosti

| Seriya | Vrijeme prethođenja | Ukupna ocjena (Si) | Ponder (Wi) |
|----------|---------------------|--------------------|-------------|
| S 05 | -8 | 66 | 1,20 |
| S 06 | -8 | 50 | 0,91 |
| S 20 | -8 | 54 | 0,99 |
| S 24 | -8 | 62 | 1,13 |
| S 43 | -10 | 57 | 1,04 |
| S 47 | -11 | 66 | 1,20 |
| S 54 | -7 | 54 | 0,99 |
| S 86 | -12 | 37 | 0,67 |
| S109 | -9 | 62 | 1,13 |
| S157 | -8 | 46 | 0,84 |
| S159 | -8 | 49 | 0,89 |
| ukupno | | 603 | 11,00 |
| prosjeak | -8,8 | 54,8 | |

Izvor: izračun autorica

Tablica 6. CROLEI na osnovi logaritmiranih serija

| Serija | Vrijeme prethodjenja | Ukupna ocjena (Si) | Ponder (Wi) |
|----------|----------------------|--------------------|-------------|
| S 24 | -8 | 74 | 1,00 |
| S 49 | -10 | 86 | 1,17 |
| S 81 | -12 | 66 | 0,89 |
| S 74 | -7 | 64 | 0,87 |
| S118 | -5 | 85 | 1,15 |
| S150 | -6 | 62 | 0,84 |
| S129 | -9 | 81 | 1,10 |
| S140 | -7 | 72 | 0,98 |
| S162 | -8 | 74 | 1,00 |
| ukupno | | 664 | 9,00 |
| prosjeck | -8,0 | 73,8 | |

Napomena za tablice 3-6: S_i – ukupna ocjena komponente; W_i – ponder značajnosti komponente; prosječno je vrijeme prethodjenja CROLEI indeksa = $\sum(t-m)_i \times W_i/k$, gdje je m broj mjeseci prethodjenja, $i=1,2,\dots,k$ (k je ukupan broj serija koje čine složeni indeks), a W_i ponder svakoga pojedinog pokazatelja i . W_i se izračunava kao omjer ocjene svakoga pojedinog pokazatelja i prosjeka ocjena svih pokazatelja (Bačić i sur., 2004:27).

Izvor: izračun autorica

Ako se usporede rezultati prikazani u tablicama 3. do 6, može se zamijetiti da najvišu ocjenu (S_i) po pokazatelju ima izvorni CROLEI iz 2004. (84,2), a slijedi CROLEI na osnovi logaritmiranih serija (73,8). Lošija prosječna ocjena pokazatelja u ovoj fazi razvoja alternativnih prognostičkih sustava ne treba značiti da je sustav zbog toga lošiji ili manje pouzdan. Naime, sustav ponderiranog uprosječivanja omogućuje da slabiji pokazatelji, tj. pokazatelji s nižom konačnom ocjenom, sudjeluju u indeksu s nižim udjelom (W_i) od boljih pokazatelja i time stvaraju automatsku ravnotežu zastupljenosti slabijih i boljih pokazatelja. Sa stajališta pravodobnoga, što ranijega predviđanja kretanja referentne serije, najpoželjniji je CROLEI na osnovi originalnih serija. No ukupna će se kvaliteta tog alternativnog prognostičkog sustava, kao i svih ostalih sustava, procijeniti uz pomoć nekoliko mjera prognostičke snage indeksa.

1.4. Izračun kompozitnih prognostičkih indeksa

Kao i sama metoda kojom se prepoznaju potencijalni navješćujući pokazatelji, metoda kojom se izračunava i konstruira sam indeks i dalje je *barometarska metoda*. Stoga je i izvorni CROLEI indeks iz 2004. izračunan prema metodološkim uputama NBER/BEA, a ta će se metoda upotrijebiti i za izračun alternativnih CROLEI-ja složenih indeksa. *Barometarska metoda* predviđa pet metodoloških koraka uz pomoć kojih se dobiva konačni prognostički iskaz (USDC i BEA, 1977; Zarnowitz i Boschan, 1975; Gapinski, 1982; Shiskin, 1961).

- Izračunavanje simetričnih (Shiskinovih) postotnih promjena podrazumijeva primjenu jednadžbe koja će iskazati očekivanu prosječnu stopu rasta od 0%, čime se osigurava simetričnost pozitivnih i negativnih promjena:

$$c_{it} = 200(X_{it} - X_{it-1}) / (X_{it} + X_{it-1}) \quad (2)$$

gdje je X_{it} vrijednost navješćujućeg pokazatelja i u razdobljima t i $t-1$, a c_i su njegove simetrične mjesečne postotne promjene ($i = 1, 2, 3, \dots, k$, pri čemu je k ukupan broj serija koje ulaze u složeni indeks; $t = 2, 3, 4, \dots, n$).

- Standardizacija amplitude podrazumijeva da se za svaki navješćujući pokazatelj izračunava tzv. standardizacijski faktor (srednja apsolutna postotna promjena):

$$A_i = \sum_{t=2}^n |c_{it}| / (N - 1) \quad (3)$$

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

$$s_{it} = c_{it} / A_i \quad (4)$$

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

- Ponderiranje standardiziranih promjena provodi se na osnovi ocjena najboljih navješćujućih pokazatelja, pri čemu se izračunavaju njihovi ponderi značajnosti, koji odražavaju ponašanje tih serija u odnosu prema referentnoj seriji:

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

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

$$R_t = (\sum_{i=1}^k s_{it} W_i) / (\sum_{i=1}^k W_i) \quad (6)$$

- Standardizacija R_t obavlja se uz pomoć standardizacijskog faktora skupine navješćujućih pokazatelja F , koji se izračunava prema jednadžbi:

$$F = [(\sum_{t=2}^n |R_t|) / (N - 1)] / [(\sum_{t=2}^n |P_t|) / (N - 1)] \quad (7)$$

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

$$r_t = R_t / F \quad (8)$$

gdje r_t označava prilagođene ponderirane mjesečne promjene skupine navješćujućih pokazatelja.

- Pretvaranje mjesečnih promjena u indeks posljednji je korak u izračunu indeksa. Seriju (ne)standardiziranih prosječnih promjena izražavamo u obliku indeksa primjenom izraza:

$$I_t = I_{t-1} [(200 + r_t) / (200 - r_t)] \quad (9)$$

gdje se za početnu vrijednost indeksa uobičajeno uvrštava indeks 100. Taj 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 indeksom novoga baznog razdoblja. Detaljnija se objašnjenja metode mogu pronaći u Bačić i sur. (2004).

Slijedeći metodološke upute za izračun indeksa, uz izvorni CROLEI iz godine 2004, dobivamo šest alternativnih CROLEI prognostičkih indeksa iz tri alternativna prognostička sustava. Slijedi opis svih indeksa proizašlih iz izvornog sustava i alternativnih sustava.

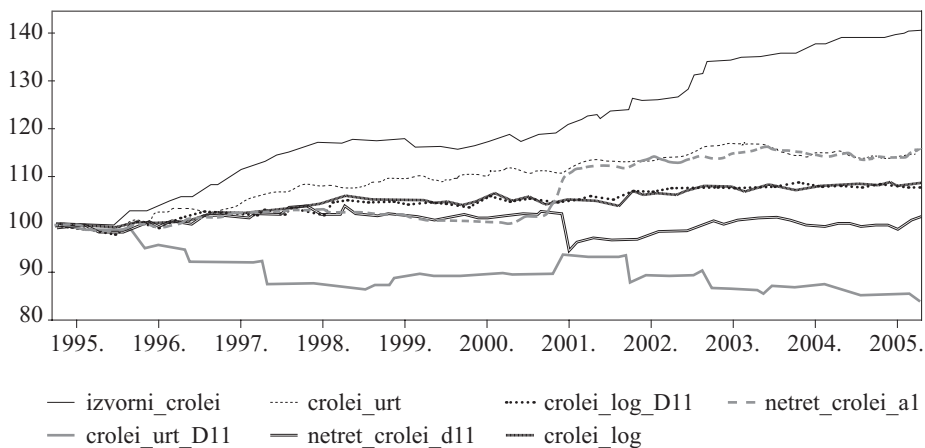
- *Izvorni CROLEI indeks iz godine 2004.* izračunan je na osnovi desezoniranih serija. U radu je indeks izložen na isti način na koji je izračunan i prikazan u posljednjoj reviziji prognostičkoga sustava u godini 2004. Referenta je serija – industrijska proizvodnja – također desezonirana.
- *CROLEI sustav na osnovi originalnih*, dakle, samo deflacioniranih serija. To znači da je Grangerov test proveden na osnovi serija koje su bile deflacionirane, ali ne i desezonirane. Nakon odabira komponenti indeksa indeks je moguće izračunati na osnovi serija koje su ostale u izvornom obliku, dakle na osnovi originalnih serija ili na osnovi serija koje su desezonirane. Stoga je taj sustav dao dva indeksa. Na istom su načelu izračunani i ostali alternativni indeksi. Referentna je serija – industrijska proizvodnja – za prvi indeks originalna, a za drugi je desezonirana.
- *CROLEI sustav je na osnovi serija u diferencijama* prema rezultatima testa stacionarnosti dobiven na osnovi Grangerova testa provedenoga na desezoniranim seri-

jama koje su u diferencijama. Naime, Grangerov je test proveden samo nad onim serijama koje su se u testovima jediničnih korijena pokazale nestacionarnima u razinama i stacionarnima u prvim diferencijama, čime se nastojao riješiti potencijalni problem *lažne regresije*. Takav sustav, kao prvo, može proizvesti indeks koji se može izračunati na osnovi serija u diferencijama. U tom je slučaju industrijska proizvodnja također testirana na stacionarnost i kasnije se kao referentna serija pojavljuje u diferencijama. Kao drugo, sustav može proizvesti indeks na osnovi desezoniranih vrijednosti, pa se za taj slučaj kao referentna serija pojavljuje industrijska proizvodnja koja je desezonirana.

- Jednako tako, *CROLEI sustav na osnovi logaritmiranih serija* daje indeks na osnovi desezoniranih logaritmiranih serija i indeks na osnovi desezoniranih serija. Za prvi je indeks referentna serija logaritmirani opseg industrijske proizvodnje, a za drugi je indeks referentna serija desezonirana industrijska proizvodnja.

Treba istaknuti da referentna serija ni na koji način ne sudjeluje u sustavu u samome izračunu kompozitnoga prognostičkog indeksa, već ponajprije služi kao aproksimacija ukupnoga kretanja gospodarstva. Uvrstiti industrijsku proizvodnju u izračun indeksa značilo bi da je stvorena snažna pristranost zato što proteklo kretanje industrijske proizvodnje može objasniti kretanje industrije u sadašnjosti. Kao drugo, uz pomoć referentne serije provjerit će se prognostička snaga svih prognostičkih indeksa – izvornoga i alternativnih.

Slika 1. Izvorni i alternativni CROLEI prognostički indeksi^a, siječanj 1995=100



^a CROLEI indeksi na osnovi: diferenciranih serija – *Crolei_urt*; desezoniranih serija iz CROLEI sustava na osnovi serija u diferencijama – *Crolei_urt_D11*; logaritmiranih serija – *Crolei_log*; desezoniranih serija iz CROLEI sustava na osnovi logaritmiranih serija – *Crolei_log_D11*; originalnih serija – *Netret_crolei_a1*; desezoniranih serija iz CROLEI sustava na osnovi originalnih serija – *Netret_crolei_d11*.

Izvor: izračun autorica

Kao prva i osnova mjera statističke povezanosti dviju varijabli pojavljuje se koeficijent korelacije za CROLEI i opseg industrijske proizvodnje, ali s vremenskim pomakom unatrag za CROLEI indeks. Rezultati su dostupni u tablici 7. Najviši je koeficijent korelacije ustanovljen za izvorni CROLEI, a s jednako uvjerljivim i visokim koeficijentom za CROLEI sustav na osnovi logaritmiranih serija (stupci 6. i 7). Kategoriji prihvatljivih indeksa pripada i CROLEI indeks na osnovi originalnih serija.

Kao dodatni pokazatelj pouzdanosti sustava i indeksa može poslužiti Grangerov test uzročnosti o kojemu je već bilo riječi. Za vremenski-unatrag-pomaknuti CROLEI i pripadajući opseg industrijske proizvodnje, prema rezultatima testa utvrđeno je da uzročnost postoji u tri slučaja. To su izvorni CROLEI indeks, za koji test ustrajno daje rezultate prema kojima uzročnost postoji na svim testiranim vremenskim pomacima, a oni variraju od -12 do -4. Postojanje uzročnosti utvrđeno je i za CROLEI na osnovi originalnih serija te za CROLEI na osnovi logaritmiranih serija. Budući da se rezultati testa uzročnosti i koeficijenti korelacije podudaraju jer su indeksi za koje je utvrđena uzročnost ujedno indeksi s visokim koeficijentima korelacije, to dodatno potvrđuje vjerodostojnost triju prognostičkih indeksa.

Tablica 7. Rezultati Grangerova testa i koeficijent korelacije u presjeku

| Prognostički sustavi CROLEI | izvorni iz 2004. | na osnovi originalnih serija | | na osnovi serija u diferencijama prema rezultatima testa stacionarnosti | | na osnovi logaritmiranih serija | |
|--|---------------------|------------------------------|---------------------|---|---------------------|---------------------------------|---------------------|
| Prognostički indeks na osnovi | desezonirana serija | originalna serija | desezonirana serija | serija u diferencijama | desezonirana serija | logaritmirana serija | desezonirana serija |
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| Vrijeme prethođenja indeksa (u mjesecima) | -5,7 | -10,6 | -10,6 | -8,8 | -8,8 | -8,0 | -8,0 |
| Koeficijent korelacije | 0,70 | 0,46 | -0,08 | 0,01 | -0,47 | 0,64 | 0,58 |
| Rezultati Grangerova testa: postoji li uzročnost prema industriji? | DA | DA | NE | NE | NE | DA | NE |
| Vremenski pomaci na kojima je ustanovljena uzročnost | od -12 do -4 | od -6 do -4 | / | / | / | -4 | / |

Napomena: Testirane su varijable za vremenski-unatrag-pomaknuti CROLEI indeks i za pripadajuću referentnu seriju – fizički opseg industrijske proizvodnje.

Izvor: izračun autorica

2. Vrednovanje izvornoga i alternativnih prognostičkih indeksa uz pomoć signalne metode

Jedna od poteškoća koja se pojavila tijekom izrade ovoga rada jest pronalazak i odabir složenijih mjera uz pomoć kojih bi se mogla vrednovati prognostička snaga izvornoga i alternativnih prognostičkih indeksa. Zbog toga su autorice bile prisiljene posegnuti za pomoćnim mjerama ekonomske prognostike koje su posredno povezane s *barometarskom metodom*, i to tako da područja u kojima nalazimo te mjere prognostičke snage potječu iz primjene *barometarske metode*. Takvo je područje *signalna metoda* i njezina primjena u predviđanju kriza ili poremećaja.⁴ Slično barometarskoj metodi, signalna metoda podrazumijeva odabir najboljih navješćujućih pokazatelja ekonomskog poremećaja, a za tu se svrhu primjenjuje matrica s nekoliko mjera koje služe kao kriteriji za odabir pokazatelja (Kaminsky, Lizondo i Reinhart, 1997; Nierhaus, 2000).

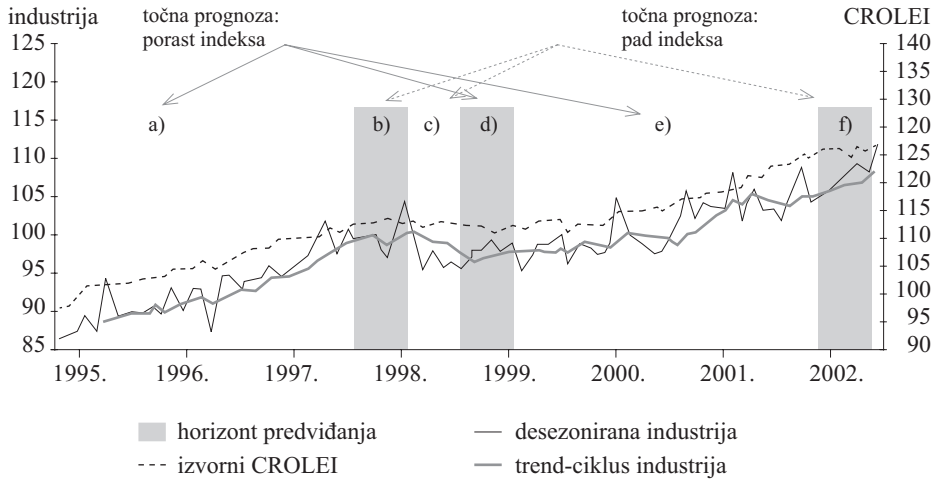
No prije nego što objasnimo kakve su mjere posrijedi, potrebno je ukratko objasniti na kojim načelima funkcionira signalna metoda, kao i najvažnije pojmove. Kao što sam naziv metode govori, njezina su osnova signali koje daju potencijalni pokazatelji, a signal se proizvodi tako što pokazatelji prelaze svoju kritičnu vrijednost ili prag u određenom razdoblju prije nego što nastane zaokret. Ključno je pritom razlikovati dvije vrste razdoblja. Postoje razdoblja koja su mirna, tj. u kojima se ne očekuje zaokret, i ona koja prethode zaokretu, a koja se nazivaju *signalni horizont*. Dobar pokazatelj u *mirnim* razdobljima neće proizvoditi signale. To znači da će njegova vrijednost ostati ispod kritičnoga praga. U signalnom horizontu dobar će pokazatelj proizvoditi signale prelazeći svoju kritičnu vrijednost i na taj će način upozoriti na skori zaokret. U primjeni signalne metode trajanje signalnoga horizonta autori mogu sami odrediti oslanjanjem na ekonomske zakonitosti i logiku.

Kako se opisano vrednovanje pokazatelja može primijeniti vezano za prognostičke indekse? Zadatak je prognostičkoga indeksa da predvidi točke zaokreta u gospodarskoj aktivnosti. No kao posljedica prilagodbe NBER metode, CROLEI indeks, uz to što omogućuje predviđanje zaokreta, kontinuirano predviđa kretanje gospodarske aktivnosti aproksimirano opsegom industrijske proizvodnje. Točke zaokreta u industrijskoj proizvodnji tijekom razdoblja 1995-2004. identificirane su kao lokalni minimumi i maksimumi u posljednjoj reviziji CROLEI indeksa u kolovozu 1995, 1998, 1999. i rujnu 2002. (Bačić i sur., 2004).

Signalni je horizont iz signalne metode u barometarskoj metodi *horizont predviđanja*, što je zapravo *vrijeme prethođenja* referentnoj seriji, koje je već izračunano za svaki indeks posebno (v. tabl. 3-6). S obzirom na signalnu metodu, određivanje horizonta predviđanja je napredak jer je trajanje egzaktno određeno izračunom, dok se u signalnoj metodi autori sami odlučuju za trajanje horizonta. No time je i postavljen stroži kriterij za utvrđivanje točnih prognoza jer npr. postoji mogućnost da indeks neposredno prije početka horizonta predviđanja navijesti zaokret. Razdoblja izvan horizonta predviđanja mirna su razdoblja ili razdoblja bez zaokreta u gospodarskoj aktivnosti, a na slici 2. označena su kao područja a), c) i e).

⁴ Riječ je o valutnim poremećajima.

Slika 2. Horizont predviđanja za izvorni CROLEI indeks (kolovoz 1995 – rujan 2002)



Izvor: DZS (2004); izračun autorica

Iz slike 2. može se zamijetiti da nije obuhvaćen horizont predviđanja prije prvog zaokreta gospodarske aktivnosti, koji se dogodio u kolovozu 1995. Razlog tome je nedovoljan broj opservacija ispred te točke. Naime, iako bi šest opservacija bilo dovoljno da se uključi horizont predviđanja za izvorni CROLEI indeks, alternativni CROLEI indeksi imaju dulje horizonte predviđanja (u trajanju od -11, -9 i -8 mjeseci), pa se ti horizonti predviđanja ne bi mogli uključiti u proces vrednovanja indeksa.

Budući da je svaka mjesečna vrijednost CROLEI-ja, u kontekstu prijašnjih vrijednosti u seriji, osnova za prognozu, mjesečne se vrijednosti CROLEI-ja po uzoru na signalnu metodu, mogu smatrati prognozama koje daju signale. Slijedeći logiku signalne metode, utvrđuje se broj dobrih i loših prognoza u horizontu predviđanja i u razdobljima bez zaokreta, i to: a) prognozama koje u horizontu predviđanja navijeste zaokret pripisuje se vrijednost 1, dok se prognozama koje propuste navijestiti zaokret pripisuje vrijednost 0; i b) prognozama koje navješćuju zaokret u mirnim razdobljima pripisuje se vrijednost 0, dok se prognozama koje ne navješćaju zaokret pripisuje vrijednost 1.

Da bismo znali kakvu vrijednost pripisati prognozi u horizontu predviđanja, prije svega moramo znati o kakvome je zaokretu riječ, a to je već poznato iz posljednje revizije indeksa (Bačić i sur., 2004). Prva točka zaokreta – kolovoz 1998. – vrh je ciklusa, a zatim slijede točka zaokreta u kolovozu 1999, koja je dno ciklusa, i rujan 2002, koji je vrh ciklusa. Stoga očekujemo da u horizontima predviđanja ispred prvog zaokreta pad vrijednosti indeksa navijesti pad gospodarske aktivnosti, dok u horizontu predviđanja ispred sljedeće točke zaokreta očekujemo da indeks iskaže porast i time navijesti uzlet gospodarske aktivnosti. Pred posljednjom točkom zaokreta, u rujnu 2002, očekuje se pad indeksa. U mirnom razdoblju a) i e) vrijednosti indeksa trebaju rasti, dok u mirnom razdoblju c) vrijednosti indeksa trebaju padati. Prognostička će se snaga vrednovati na osnovi matrice prikazane tablicom 8.

Prilagođeni omjer netočnih i točnih prognoza pokazatelj je sposobnosti indeksa da proizvede točne prognoze bez nudiženja netočnih prognoza. Stoga će ta mjera poslužiti kao osnovni pokazatelj prognostičke snage pokazatelja. Što je omjer bliži nuli, to je indeks uspješniji u prognoziranju.

Tablica 8. Matrica za vrednovanje prognostičke snage indeksa^a

| | Horizont predviđanja | Razdoblje bez zaokreta | Ukupno prognoza |
|--|----------------------|------------------------|-------------------|
| Prognoza predviđa zaokret ($P_t = 1$) | A | B | A+B |
| Prognoza ne predviđa zaokret ($P_t = 0$) | C | D | C+D |
| Ukupno prognoza | A+C | B+D | A+B+C+D |
| Točne prognoze | A | D | A+D |
| Netočne prognoze | C | B | C+B |
| Točne prognoze kao postotak ukupnih prognoza | $A/(A+C)$ | $D/(B+D)$ | $(A+D)/(A+B+C+D)$ |
| Netočne prognoze kao postotak ukupnih prognoza | $C/(A+C)$ | $B/(B+D)$ | $(B+C)/(A+B+C+D)$ |
| Prilagođeni omjer netočnih i točnih prognoza | $B/(B+D)/A/(A+C)$ | | |

^a Prema Kaminsky, Lizondo i Reihart (1997) i Nierhaus (2000).

Izvor: prilagođeno prema Ahec-Šonje, Babić i Bačić (2003)

Ako indeks daje netočne prognoze, tj. ako navješćuje zaokrete u mirnom razdoblju, omjer će biti bliži 1, pa indeksi s mjerom blizu ili višim od 1 nisu vjerodostojni u naviještaju gospodarske aktivnosti. Na osnovi matrice izračunane su mjere prognostičke snage izvornoga i alternativnih prognostičkih indeksa (tabl. 9-15).

Tablica 9. Izvorni CROLEI indeks iz 2004.

| | | | |
|--|-------------------------------------|------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 18 |
| - razdoblju bez zaokreta | | | 67 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 7 | 13 | 20 |
| p = 0 | 11 | 54 | 65 |
| Ukupno | 18 | 67 | 85 |
| Točna prognoza | 7 | 54 | 61 |
| Točna prognoza/ukupno | 0,39 | 0,81 | 0,72 |
| Netočna prognoza/ukupno | 0,61 | 0,19 | 0,28 |
| NTS | 0,50 | | |

Tablica 10. CROLEI indeks na osnovi originalnih serija iz sustava,
 na osnovi originalnih serija

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 33 |
| - razdoblju bez zaokreta | | | 52 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 12 | 18 | 30 |
| p = 0 | 21 | 34 | 55 |
| Ukupno | 33 | 52 | 85 |
| Točna prognoza | 12 | 34 | 46 |
| Točna prognoza/ukupno | 0,36 | 0,65 | 0,54 |
| Netočna prognoza/ukupno | 0,64 | 0,35 | 0,46 |
| NTS | 0,95 | | |

Tablica 11. CROLEI indeks na osnovi desezoniranih serija iz sustava,
 na osnovi originalnih serija

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 33 |
| - razdoblju bez zaokreta | | | 52 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 11 | 17 | 28 |
| p = 0 | 22 | 35 | 57 |
| Ukupno | 33 | 52 | 85 |
| Točna prognoza | 11 | 35 | 46 |
| Točna prognoza/ukupno | 0,33 | 0,67 | 0,54 |
| Netočna prognoza/ukupno | 0,67 | 0,33 | 0,46 |
| NTS | 0,98 | | |

Tablica 12. CROLEI indeks u diferencijama iz sustava, na osnovi serija
 u diferencijama prema rezultatima testa stacionarnosti

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 27 |
| - razdoblju bez zaokreta | | | 58 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 14 | 20 | 34 |
| p = 0 | 13 | 38 | 51 |
| Ukupno | 27 | 58 | 85 |
| Točna prognoza | 14 | 38 | 52 |
| Točna prognoza/ukupno | 0,52 | 0,66 | 0,61 |
| Netočna prognoza/ukupno | 0,48 | 0,34 | 0,39 |
| NTS | 0,67 | | |

Tablica 13. CROLEI indeks na osnovi desezoniranih serija iz sustava, na osnovi serija u diferencijama prema rezultatima testa stacionarnosti

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 27 |
| - razdoblju bez zaokreta | | | 58 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 16 | 30 | 46 |
| p = 0 | 11 | 28 | 39 |
| Ukupno | 27 | 58 | 85 |
| Točna prognoza | 16 | 28 | 44 |
| Točna prognoza/ukupno | 0,59 | 0,48 | 0,52 |
| Netočna prognoza/ukupno | 0,41 | 0,52 | 0,48 |
| NTS | 0,87 | | |

Tablica 14. CROLEI indeks na osnovi logaritmiranih serija iz sustava na osnovi logaritmiranih serija

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 24 |
| - razdoblju bez zaokreta | | | 61 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 13 | 27 | 40 |
| p = 0 | 11 | 34 | 45 |
| Ukupno | 24 | 61 | 85 |
| Točna prognoza | 13 | 34 | 47 |
| Točna prognoza/ukupno | 0,54 | 0,56 | 0,55 |
| Netočna prognoza/ukupno | 0,46 | 0,44 | 0,45 |
| NTS | 0,82 | | |

Tablica 15. CROLEI indeks na osnovi desezoniranih serija iz sustava, na osnovi logaritmiranih serija

| | | | |
|--|--|---------------------------|--------|
| Broj opservacija u: | | | 85 |
| - horizontu predviđanja pred zaokretom | | | 24 |
| - razdoblju bez zaokreta | | | 61 |
| | Horizont predviđanja prije zaokreta | Razdoblje bez zaokreta | Ukupno |
| p = 1 | 11 | 29 | 40 |
| p = 0 | 13 | 32 | 45 |
| Ukupno | 24 | 61 | 85 |
| Točna prognoza | 11 | 32 | 43 |
| Točna prognoza/ukupno | 0,46 | 0,52 | 0,51 |
| Netočna prognoza/ukupno | 0,54 | 0,48 | 0,49 |
| NTS | 1,04 | | |

Izvor za tablice 9-15: izračun autorica

Prema dobivenim rezultatima izračuna mjera u matrici, najniži je prilagođeni omjer točnih i netočnih prognoza (0,50) postigao izvorni CROLEI. Slijedi CROLEI u diferencijama s omjerom točnih i netočnih prognoza 0,67. Iako je riječ o drugom najboljem rezultatu, on sa stajališta signalne metode nije prihvatljiv jer 39% njegovih prognoza nije točno dok je taj udio kod izvornoga CROLEI indeksa znatno niži – samo 28%.

2.1. Vrednovanje indeksa uz pomoć ocjena regresijskih prognostičkih modela

Budući da smo rezultate iz matrica dobili modificiranjem signalne metode prema osnovama barometarske metode, te rezultate želimo provjeriti metodom koju ne treba prilagođivati potrebama rada, dakle, metodom koja se primjenjuje u originalu. Odabrana su dva prognostička regresijska modela koji će se primijeniti u dva empirijska koraka. U prvome se koraku ocjenom modela omogućuje usporedba prognostičke snage izvornoga i alternativnih CROLEI indeksa. U drugome se koraku provodi regresijska analiza na osnovi koje je moguće dati prognozu kretanja industrijske proizvodnje za uzorak, koji obuhvaća opservacije od siječnja 1995. do travnja 2003. Modeli koji se ocjenjuju na osnovi svih CROLEI prognostičkih indeksa, uključujući izvorni, jesu:

$$INDUSTRIJA_t = \alpha_0 + \alpha_1 CROLEI_{t-1} + \alpha_2 CROLEI_{t-2} + \dots + \alpha_n CROLEI_{t-n} + \varepsilon_t \quad (10)$$

$$INDUSTRIJA_t = \alpha_0 + \beta_i CROLEI_{t_n} + \varepsilon_t \quad (11)$$

gdje je $INDUSTRIJA_t$ ukupni opseg industrijske proizvodnje⁵ u vremenu t , $CROLEI_t$ je vrijednost odabranog CROLEI kompozitnog indeksa u razdoblju $t-1$, a n je prosječno vrijeme prethođenja CROLEI prognostičkoga indeksa. Pri ocjeni modela (10), CROLEI sustav na osnovi originalnih serija s vremenom prethođenja od 11 mjeseci imat će 11 objašnjavajućih varijabli i konstantu. U drugome će pak modelu objašnjavajuća varijabla biti samo CROLEI indeks s vremenskim pomakom od 11 mjeseci unatrag, a dio modela ponovno će činiti konstanta. Ista logika vrijedi i za ostale CROLEI indekse, odnosno za ostale regresijske jednadžbe koje treba ocijeniti.

Ocjena regresijskih modela (10) i (11) za svih sedam CROLEI prognostičkih indeksa u sljedećem će koraku poslužiti za dobivanje prognoze kretanja industrijske proizvodnje. Razdoblje na koje se prognoza odnosi jest svibanj 2003 – travanj 2004. Prednost je te metode to što se dobivena prognoza industrijske proizvodnje može usporediti sa stvarnom vrijednošću – serijom *fizički opseg industrijske proizvodnje*. Na osnovi razlike između prognozirane i stvarne vrijednosti industrijske proizvodnje izračunavaju se tri pokazatelja prognostičke snage:

⁵ Serija *INDUSTRIJA* transformirana je u skladu s transformacijom komponenti CROLEI prognostičkog sustava s kojim se stavlja u statistički međusobni odnos.

- prosječna pogreška

$$RMSE = \sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}; \quad (12)$$

- srednja apsolutna pogreška

$$MAE = \sum_{t=T+1}^{T+h} |\hat{y}_t - y_t| / h; \quad (13)$$

- srednja apsolutna postotna pogreška

$$MAPE = 100 \times \sum_{t=T+1}^{T+h} \left| \frac{\hat{y}_t - y_t}{y_t} \right| / h; \quad (14)$$

gdje je $t = T+1, T+2, \dots, T+h$ razdoblje koje će se prognozirati, h ukupan broj opservacija predviđenih za prognozu unutar uzorka, a y_t i \hat{y}_t stvarna i prognozirana vrijednost industrijske proizvodnje. Prema tim testovima, najbolji je onaj prognostički sustav koji u sva tri testa ostvari najnižu vrijednost test-statistike. No pažljivom usporedbom opisanih mjera može se uočiti da prve dvije mjere ovise o apsolutnoj vrijednosti opservacija unutar promatranoga i prognozirano vremenskoga niza. Za treću se mjeru – srednju apsolutnu postotnu pogrešku, razlika između prognozirane i stvarne vrijednosti uprosječuje stvarnom vrijednosti vremenske serije za svaku točku u vremenu.

Tablica 16. Ocjena sposobnosti CROLEI indeksa za prognozu industrijske proizvodnje unutar uzorka – model (10)

| Prognostički sustavi CROLEI | izvorni iz 2004. | na osnovi originalnih serija | | na osnovi serija u diferencijama prema rezultatima testa stacionarnosti | | na osnovi logaritmiranih serija | |
|--|---------------------|------------------------------|---------------------|---|---------------------|---------------------------------|---------------------|
| Prognostički indeks na osnovi | desezonirana serija | originalna serija | desezonirana serija | serija u diferencijama | desezonirana serija | logaritmirana serija | desezonirana serija |
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| Vrijeme prethođenja (horizont predviđanja) | -6 | -11 | -11 | -9 | -9 | -8 | -8 |
| Prosječna pogreška | 3,146 | 8,92 | 16,78 | 9,301 | 10,85 | 1,05 | 1,29 |
| Srednja apsolutna pogreška | 2,659 | 7,31 | 16,52 | 8,75 | 10,65 | 0,98 | 1,18 |
| Srednja apsolutna postotna pogreška | 2,185 | 5,33 | 13,66 | 7,22 | 8,801 | 0,98 | 1,14 |

Izvor: izračun autorica

Srednja apsolutna postotna pogreška najpogodnija je za usporedbu prognostičke sposobnosti svih CROLEI prognostičkih indeksa, dok su prve dvije mjere prognostičke pogreške prikladne samo za:

- usporedbu razlika u prognostičkoj snazi između CROLEI indeksa unutar istih sustava: između indeksa iz stupaca 2 i 3; između indeksa iz stupaca 4 i 5; i između indeksa iz stupaca 6 i 7 iz tablice 17, zbog toga što jedina razlika između parova indeksa unutar istog sustava nastaje kada se parovi iz indeksa konstruiraju ili na osnovi desezoniranih ili na osnovi tretiranih serija;
- usporedbu prognostičke snage CROLEI indeksa ocijenjenoga modelom (1) i modelom (2).

Iz rezultata u tablici 16. i 17. može se zaključiti da najvišu prognostičku moć ima CROLEI indeks na osnovi serija u logaritmima (stupac 6). Takav je rezultat bio očekivan pri primjeni prvih dviju mjera prognostičke snage jer je razlika između prognozirane i stvarne vrijednosti u serija s logaritmima znatno manja nego u serija s desezoniranim ili transformiranim podacima. Ipak, vrijednost treće mjere – srednje apsolutne postotne pogreške – također upućuje na to da CROLEI sustav na osnovi logaritamskih vrijednosti ima bolju mogućnost prognoziranja primjenom obaju modela od izvornoga CROLEI indeksa. Najslabiju je prognostičku vrijednost iskazao CROLEI sustav na osnovi originalnih serija. Rangiranje indeksa prema prognostičkoj snazi nije se pokazalo osjetljivim na izbor prognostičkih modela (10) ili (11), čime je dodatno potvrđena postojanost dobivenih rezultata.

Tablica 17. Ocjena sposobnosti CROLEI indeksa za prognozu industrijske proizvodnje unutar uzorka – model (11)

| Prognostički sustavi CROLEI | izvorni iz 2004. | na osnovi originalnih serija | | na osnovi serija u diferencijama prema rezultatima testa stacionarnosti | | na osnovi logaritmiranih serija | |
|---|---------------------|------------------------------|---------------------|---|---------------------|---------------------------------|---------------------|
| Prognostički indeks na osnovi | desezonirana serija | originalna serija | desezonirana serija | serija u diferencijama | desezonirana serija | logaritmirana serija | desezonirana serija |
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| Vrijeme prethodjenja (horizont predviđanja) | -6 | -11 | -11 | -9 | -9 | -8 | -8 |
| Prosječna pogreška | 3,078 | 7,91 | 17,68 | 8,17 | 12,76 | 1,05 | 1,18 |
| Srednja apsolutna pogreška | 2,600 | 6,19 | 17,52 | 7,61 | 12,55 | 1,01 | 1,11 |
| Srednja apsolutna postotna pogreška | 2,14 | 4,55 | 14,50 | 6,27 | 10,38 | 0,97 | 1,07 |

Izvor: izračun autorica

No treba istaknuti da se ne bi smio donijeti jednoznačan zaključak o tome da je CROLEI sustav na osnovi logaritamskih vrijednosti sustav s najvećom prognostičkom moći. Ako modele (10) i (11) ocijenimo tako da kao neovisna varijabla posluži izvorni CRO-

LEI indeks, a kao zavisna logaritmirana vrijednost industrijske proizvodnje, tada izvorni CROLEI indeks prema sve tri mjere prognostičke snage ima najbolji rezultat, tj. najveću prognostičku vrijednost. Zbog toga izvorni CROLEI indeks ipak ima prednost pred CROLEI sustavom na osnovi logaritmiranih vrijednosti.⁶

Dobiveni rezultati vode zaključku da izvorni CROLEI, osim što dobro predviđa ponašanje desezonirane industrijske proizvodnje, još bolje prognozira vrijednosti industrijske proizvodnje u logaritmima. Obrnuto ne vrijedi. Indeksima CROLEI sustava na osnovi logaritamskih vrijednosti dobro se prognozira isključivo kretanje industrijske proizvodnje u logaritmima, dok im je moć predviđanja desezoniranog kretanja industrijske proizvodnje zanemariva.⁷

Nadalje, iz rezultata prikazanih u tablici 16. i 17. može se uočiti da svi alternativni CROLEI indeksi imaju veću prognostičku moć ako su konstruirani na osnovi serija koje nisu samo desezonirane, već su naknadno transformirane. To znači da, primjerice, veću prognostičku snagu ima CROLEI na osnovi serija u diferencijama nego CROLEI na osnovi desezoniranih serija u CROLEI sustavu na osnovi serija u diferencijama. Razlika je najveća u CROLEI sustavu na osnovi originalnih serija. Taj se rezultat može objasniti sezonskom prilagodbom podataka. Primjenom programa za sezonsku prilagodbu X11ARIMA izglađuju se serije, pri čemu se gubi dio informacijskog sadržaja (Enders, 1995). Izgubljeni informacijski sadržaj značajan je jer može znatno unaprijediti prognostičku moć bilo kojega modela, što se očitovalo i u rezultatima. Kada se pri razvijanju prognostičkih modela pojave problemi koji nastaju kao posljedica desezoniranja, istraživači pribjegavaju uporabi sezonskih *dummy varijabli* (Campos i Ericsson, 1999).

Rezultati dobiveni u ovome dijelu rada ne upućuju na to da je izvorni CROLEI indeks u odnosu prema alternativnim prognostičkim izrazima slabiji pokazatelj budućih kretanja. Upravo suprotno, tri mjere pogrešaka nastalih pri predviđanju usuglašeno su pokazale da ne postoji osnova za zamjenu izvornoga CROLEI-ja nekim od ponuđenih alternativnih izraza. Ovaj je dio rada zapravo potvrdio rezultate koji su dobiveni u prethodnim dijelovima rada – a svi oni upućuju na to da CROLEI treba ostati u svome starome ruhu.

3. Osvrt na prijedlog prognostičkog sustava iz 2005.

U Nizozemskoj se objavljuje šest prognostičkih izraza, u Njemačkoj najmanje pet (Reijer, 2006; Dreger i Schumacher, 2005), a u Hrvatskoj zasad samo jedan, CROLEI. No i u nas se dogodio pomak. Godine 2005. objavljen je prijedlog novoga kompozitnog pokazatelja hrvatskoga gospodarstva (Cerovac, 2005). Prema nama raspoloživim informacijama, riječ je o prvom i jedinom radu o temi cikličnih pokazatelja nakon razvoja CROLEI sustava. Budući da je rad objavljen kao radna verzija te se kretanje kompozitnog indeksa još uvijek ne objavljuje, kritički se može razmatrati samo izbor metoda koje čine metodološki okvir i, eventualno, rezultati u godini objave.

⁶ Prosječna pogreška za model (10), u kojemu je izvorni CROLEI indeks neovisna varijabla, a logaritmirana vrijednost industrijske proizvodnje zavisna varijabla, iznosi 0,59, srednja apsolutna pogreška 0,39, a srednja apsolutna postotna pogreška 0,37. Vrijednosti tih testova za model (11) s istom neovisnom i zavisnom varijablom iznose 0,60, 0,39 i 0,38.

⁷ Model (10): RMSE: 8,44; MAE: 8,04; MAPE: 6,63; model (11): RMSE: 8,00; MAE: 7,61; MAPE: 6,28.

Cerovac (2005) koristi se kombinacijom različitih metodoloških koraka koji se mogu pripisati metodološkom okviru NBER. Njegov rad počinje identificiranjem industrijske proizvodnje kao referentne serije i određivanjem točaka zaokreta za dulje razdoblje (1992-2004) uz pomoć *Bry-Boschanova algoritma*.⁸ Cerovac zatim prelazi na određivanje prethodećih, pratećih i zaostajućih pokazatelja. Cijeli proces naziva metodom *eliminacije*, a njome zamjenjuje postupak *ocjenjivanja* pokazatelja. Ipak, autor se koristi NBER kriterijima zadanim u postupku ocjenjivanja, ali zato da bi prema njima uklonio nezadovoljavajuće serije. Uz to, autor primjenjuje *korelacijsku analizu uz uvođenje vremenskih pomaka* kojom nastoji mjeriti usklađenost faza ciklusa referentne serije i pokazatelja, kao i tendencije njihova predvođenja. Uz pomoć nje, Cerovac određuje vrijeme prethođenja, koje je ondje gdje je vrijednost korelacijskoga koeficijenta najveća, dok mu predznak koeficijenta govori je li pokazatelj prethodeći, prateći ili zaostajući.⁹

Rezultat primjene metode eliminacije izuzetno je nizak broj pokazatelja u samom *prethodećem kompozitnom pokazatelju*. Riječ je o ukupno tri komponente (zasnovane na, čini se, pet serija): prodajnoj marži; odnosu depozita i kredita u sektoru poduzeća te odnosu proizvodnje i zaliha u industriji. Naš je zaključak da pristup eliminacije serija nije rezultirao zadovoljavajućim izborom komponenti. Prvu je komponentu, *prodajnu maržu*, autor procijenio, čemu bi u sustavu ocjenjivanja serija prema NBER kriteriju *statističke značajnosti* bilo dodijeljeno nula bodova. To znači da ta serija i prema autorovoj metodi eliminacije ne bi smjela biti uključena u indeks. Osobito je problematična treća komponenta, *odnos proizvodnje i zaliha u industriji*. Kako je industrijska *proizvodnja* referentna serija sustava, odluka da se uključi u treću komponentu prognostičkoga sustava znači da je zanemarena činjenica da na buduće kretanje referentne serije može utjecati kretanje te iste varijable u prošlosti. Bez obzira na odabir metode, uključivanje referentne serije u izvedenu komponentu treba posve izbjeći jer ona stvara lažnu neslužajnu statističku povezanost druge serije u komponenti s referentnom serijom.

Novost u usporedbi s CROLEI-jem jest to što Cerovac gradi *kompozitni indeks zaostajućih pokazatelja* i *kompozitni indeks pratećih pokazatelja*, kojima je zadaća dati dodatnu informaciju o sadašnjemu i proteklom kretanju gospodarstva. Sva tri kompozitna indeksa izračunana su na osnovi TCB algoritma, koji ne obuhvaća uprosječivanje uz pomoć pondera značajnosti koji se dobivaju iz postupka ocjenjivanja. Rezultat su veće amplitude indeksa na mjesečnoj frekvenciji, čega je autor svjestan (Cerovac, 2005:23). Naime, ta poteškoća otežava utvrđivanje zaokreta u indeksu i najvjerojatnije stvara više šumova prilikom davanja prognoza. Kada se CROLEI i Cerovčev prognostički indeks grafički prikažu, jasno je da se ciklički vrlo slično kreću, s time da je CROLEI znatno glatkija serija. Usuglašenost kretanja tih dvaju indeksa može prije svega poslužiti njihovim autorima kao potvrda kvalitete vlastitih rezultata.

⁸ Primjenom te metode za razdoblje 1995-2004. dobiva gotovo identične točke zaokreta kao i autori CROLEI-ja koji su se za tu svrhu koristili određivanjem lokalnih minimuma i maksimuma. Dvije su razlike u rezultatima: autori CROLEI-ja za isto razdoblje prepoznali su na kraju razdoblja jedan zaokret više. Druga je datiranje zaokreta 1999, koji Cerovac datira nekoliko mjeseci ranije nego autori CROLEI-ja.

⁹ Serije pritom nisu stacionarne, već imaju uključenu trend-ciklus komponentu.

4. Zaključak

Osnovni je cilj ovoga rada bio ocijeniti prognostičku snagu CROLEI indeksa. Za tu svrhu, primjenom barometarske metode na osnovi koje je konstruiran CROLEI indeks, autorice sastavile šest alternativnih prognostičkih indeksa koji su međusobno, po komponentama koje čine indeks, potpuno različiti. Ako u prvi mah kao najvažniji kriterij za konstruiranje indeksa uzmemo da su vrednije komponente koje su ekonomski agregati, prednjači izvorni CROLEI. No ulaženjem u dublju analizu, koja je započela primjenom koeficijenta korelacije i Grangerova testa uzročnosti za dvije varijable, ta je ekonomska logika potvrđena. Zatim se upotrebljava *matrica za vrednovanje prognostičkih pokazatelja* koja potječe iz signalne metode. Iz dobivenih rezultata zaključujemo da matrica dobro funkcionira i za naše indekse i potvrđuje naša očekivanja. *Izvorni CROLEI*, prema najvažnijem pokazatelju iz matrice, a to je omjer točnih i netočnih prognoza, ima najbolji rezultat. Drugi najbolji rezultat koji je ostvario *CROLEI u diferencijama* nije prihvatljiv jer 39% njegovih prognoza nije točno dok je taj udio za izvorni CROLEI indeks znatno niži – 28%.

Budući da je *matrica za vrednovanje prognostičkih pokazatelja* prilagođena metoda, autori su željeli dobivene rezultate potvrditi primjenom druge metode, i to u njezinu izvornom obliku. Za tu svrhu odabrana dva regresijska modela, s industrijom kao zavisnom varijablom i prognostičkim indeksom kao objašnjavajućom varijablom. Oba su modela dala postojane, ujednačene rezultate prema kojima najbolju ocjenu ima model s *CROLEI sustavom na osnovi logaritmiranih vrijednosti*, a slijedi ga *izvorni CROLEI*. Kako objasniti takav rezultat? Odgovor je jednostavan – zato što su u CROLEI sustavu na osnovi logaritmiranih vrijednosti sve serije “izgladene”, uključujući i referentnu industrijsku proizvodnju. Ipak, CROLEI sustav na osnovi logaritmiranih vrijednosti ne previđa dobro desezoniranu industriju. S izvornim je CROLEI indeksom upravo suprotno. Naime, kada se ocijeni u modelu s logaritmiranom industrijom, on postaje najbolji pokazatelj. Zaključak je autora da je barometarska metoda, s obzirom na mogućnosti statističke osnove i gospodarske uvjete u Hrvatskoj, primijenjena na prihvatljiv način.

U radu je razmatran i prijedlog prognostičkog iskaza (Cerovac, 2005) koji je hvalevrijedan prije svega zbog dodatnih informacija o budućim kretanjima. Osim što su u istraživanju uključene neke nove, zanimljive serije, autor je izgradio kompozitne indekse zaostajućih i pratećih pokazatelja. Prvi je primijenio i Bry-Boschanov algoritam kao objektivnu metodu utvrđivanja zaokreta. No najveći je problem u radu odabir problematičnih komponenti u kompozitnom indeksu najvješćujućih pokazatelja. Ipak, pošto autor usavrši i potvrdi svoj metodološki okvir i rezultate njegove primjene, bilo bi korisno da kretanje svoga indeksa počne redovito objavljivati.

Namjera je autorica bila informirati širu javnost o vrijednosti CROLEI prognostičkoga sustava i o mogućnostima njegove upotrebe, sa svim njegovim prednostima i nedostacima. Ovo će istraživanje poslužiti kao osnova za razvoj i primjenu metodološkog aparata za precizno utvrđivanje točaka zaokreta u gospodarskim ciklusima, ali i za dodatna testiranja serija uz pomoć novih metodoloških alata. Sa svakom novom mjesečnom opservacijom potencijalnih pokazatelja korak smo bliže mogućnosti primjene novih, složenijih prognostičkih metoda. Naša je preporuka da CROLEI do sljedećeg istraživanja ipak ostane u starome ruhu.

Dodatak 1. Popis serija u CROLEI bazi

Industrija – indeks fizičkog opsega industrijske proizvodnje

- 01 industrijska proizvodnja, ukupno
- 02 rudarstvo i vađenje
- 03 prerađivačka industrija
- 04 opskrba električnom energijom, plinom i vodom
- 05 energija
- 06 intermedijarni proizvodi, osim energije
- 07 kapitalni proizvodi
- 08 trajni proizvodi za široku potrošnju
- 09 netrajni proizvodi za široku potrošnju
- 11 vađenje sirove nafte i zemnog plina; uslužne djelatnosti
- 12 vađenje ostalih ruda i kamena
- 13 proizvodnja hrane i pića
- 14 proizvodnja duhanskih proizvoda
- 15 proizvodnja tekstila
- 16 proizvodnja odjeće; dorada i bojenje krzna
- 17 prerada kože, izrada galanterije i obuće
- 18 prerada drva i proizvodi od drva, osim namještaja
- 19 proizvodnja celuloze, papira i proizvoda od papira
- 20 izdavačka i tiskarska djelatnost
- 21 proizvodnja koksa, naftnih derivata i nuklearnoga goriva
- 22 proizvodnja kemikalija i kemijskih proizvoda
- 23 proizvodnja proizvoda od gume i plastike
- 24 proizvodnja ostalih nemetalnih mineralnih proizvoda
- 25 proizvodnja metala
- 26 proizvodnja proizvoda od metala, osim strojeva i opreme
- 27 proizvodnja strojeva i uređaja
- 28 proizvodnja uredskih strojeva i računala
- 29 proizvodnja električnih strojeva i aparata
- 30 proizvodnja RTV i komunikacijskih aparata i opreme
- 31 proizvodnja medicinskih preciznih i optičkih instrumenata te satova
- 32 proizvodnja motornih vozila, prikolica i poluprikolica
- 33 proizvodnja ostalih prijevoznih sredstava
- 34 proizvodnja namještaja, ostala prerađivačka industrija
- 35 reciklaža
- 36 opskrba električnom energijom plinom, parom i toplom vodom
- 37 skupljanje, pročišćavanje i distribucija vode
- 38 indeks broja radnika u industriji
- 40 zalihe gotovih proizvoda kod proizvođača u industriji, ukupno
- 41 indeks proizvodnosti rada u industriji

Zaposlenost i plaće

- 42 broj zaposlenih, ukupno
- 43 nominalna neto plaća po zaposlenome, ukupno
- 44 prosječna mjesečna bruto plaća po zaposlenome

Nezaposlenost

- 45 novoprijavljeni radi zaposlenja tijekom mjeseca
- 46 nezaposlene osobe prema stanju krajem mjeseca
- 47 osobe koje prvi put traže zaposlenje prema stanju krajem mjeseca
- 48 zaposleni s evidencije tijekom mjeseca
- 49 prijavljene potrebe za radnicima tijekom mjeseca
- 51 korisnici novčane naknade
- 52 osobe nezaposlene zbog prestanka rada poduzeća i poslodavca

Graditeljstvo i turizam

Broj noćenja turista

- 54 ukupno
- 55 stranih
- 56 domaćih
- 53 neto narudžbe građevnih radova
- 530 indeks fizičkog opsega građevinskih radova

Trgovina

- 57 promet u trgovini na malo
- 58 zalihe u trgovini na malo

Robna razmjena RH s inozemstvom

Izvoz

- 67 roba, ukupno
- 71 hrane i žive životinje
- 72 pića i duhana
- 73 sirove materije, osim goriva
- 74 mineralnih goriva i maziva
- 75 životinjskih i biljnih ulja i masti
- 76 kemijskih proizvoda
- 77 proizvoda svrstanih prema materijalu
- 78 strojeva i transportnih uređaja
- 79 raznih gotovih proizvoda
- 80 proizvoda i transakcije, nespomenuti

Uvoz

- 81 roba, ukupno
- 85 hrane i žive životinje

- 86 pića i duhana
- 87 sirove materije, osim goriva
- 88 mineralnih goriva i maziva
- 89 životinjskih i biljnih ulja i masti
- 90 kemijskih proizvoda
- 91 proizvoda svrstanih prema materijalu
- 92 strojeva i transportnih uređaja
- 93 raznih gotovih proizvoda
- 94 proizvoda i transakcije, nespomenuti

Nefinancijske transakcije

- 95 nekonsolidirani prihodi državnoga, županijskih i općinskih proračuna

Monetarna statistika

- 105 novčana masa M1
- 106 novčana masa M1a
- 107 ukupna likvidna sredstva M4
- 108 primarni novac
- 109 gotov novac
- 110 depozitni novac
- 116 plasmani
- 120 inozemna aktiva HNB-a
- 111 depoziti središnje države u HNB-u

Štedni i oročeni depoziti u poslovnim bankama

- 112 kunski
- 113 devizni
- 114 devizni – stanovništvo
- 115 devizni – poduzeća

Kredit

- 117 ukupni
- 118 poduzećima
- 119 stanovništvu

Devizne rezerve poslovnih banaka

- 121 ukupno
- 122 tekući računi i depoziti po deviznoj štednji
- 123 oročeni depoziti i depoziti s otkaznim rokom
- 124 devizna inozemna pasiva poslovnih banaka

Kamatna stopa HNB-a

- 125 na sredstva izdvojene obvezne rezerve
- 127 na dragovoljno upisane blagajničke zapise HNB-a, od 35 dana
- 129 na lombardne kredite

Kamatna stopa poslovnih banaka

- 132 aktivna na kunske kredite bez valutne klauzule, ukupni prosjek
- 133 aktivna na kunske kredite s valutnom klauzulom, ukupni prosjek
- 134 pasivna na kunske depozite, ukupni prosjek
- 135 pasivna na štedne i oročene depozite s valutnom klauzulom

Kamatna stopa na tržištu novca

- 136 dnevno tržište
- 137 prekonoćno tržište

Prihodi i rashodi državnog proračuna

Prihodi

- 140 državnog proračuna, ukupno
- 143 porezni, ukupno
- 156 neporezni
- 140a kapitalni, ukupno
- 144 porezni, porez na dobit
- 145 porezni, porez na dohodak
- 146 porezni, porez na promet proizvoda i usluga
- 147 porezni, porez na dodanu vrijednost
- 148 porezni, carine, carinske i uvozne pristojbe
- 149 trošarine, ukupno
- 150 trošarine na naftne derivate
- 151 trošarine na alkohol
- 152 trošarine na pivo
- 153 trošarine na bezalkoholna pića
- 154 trošarine na duhan
- 155 trošarine na kavu
- 155a trošarina na motorna vozila

Rashodi

- 157 državnog proračuna, ukupno
- 158a ukupni i posudbe-otplata
- 159 bruto plaće službenika i namještenika
- 160 izdaci za ostala dobra i usluge
- 161 plaćanje kamata
- 162 tekući transferi
- 163 subvencije
- 164 kapitalni izdaci
- 158 Posudbe umanjene za otplate (*net leading*)
- 165 suficit/deficit državnog proračuna

Financiranje suficita/deficita državnog proračuna

- 166 ukupno
- 167 domaće
- 168 strano

Troškovi života i cijene

Indeks potrošačkih cijena

- 170 ukupno
- 171 robe
- 172 usluge

Indeksi cijena

- 173 industrijskih proizvoda, ukupno
- 183 građevnog materijala (1993.g.=100)
- 174 industrijskih proizvoda, energije
- 175 industrijskih proizvoda, intermedijarnih proizvoda
- 176 industrijskih proizvoda, kapitalnih proizvoda
- 177 industrijskih proizvoda, trajnih proizvoda za široku potrošnju
- 178 industrijskih proizvoda, netrajnih proizvoda za široku potrošnju
- 179 industrijskih proizvoda, rudarstva i vađenja
- 180 industrijskih proizvoda, prerađivačke industrije
- 181 industrijskih proizvoda, opskrbe električnom energijom, plinom i vodom.

LITERATURA

Ahec-Šonje, A. [et al.], 1994. *Metodološki okvir za izradu sustava prethodećih ekonomskih pokazatelja*. Osnovna studija, prilog 2. Zagreb: Ekonomski institut.

Ahec-Šonje, A. [et al.], 1996. *Navješćujući pokazatelji hrvatskog gospodarstva*. Osnovna studija. Zagreb: Ekonomski institut.

Ahec-Šonje, A., 1995. "Metode predviđanja ekonomskih fluktuacija s naglaskom na "pristup indikatora" *Ekonomski pregled*, 46 (11-12), 820-837.

Ahec-Šonje, A., Babić, A. i Bačić, K., 2003. "Determinants of currency disturbances in transition economies of Central and Eastern Europe" in: Z. Reić. *The 5th International Conference 'Enterprise in Transition'*. Split: Ekonomski fakultet, 308-311.

Ashely, R., Granger, C. W. J. and Schmalensee, R., 1980. "Advertising and Aggregate Consumption: An Analysis of Causality". *Econometrica*, 48 (5), 1149-1168.

Bačić, K. [et al.], 2004. *Usavršavanje prognostičkog indeksa hrvatskog gospodarstva*. Završna studija. Zagreb: Ekonomski institut.

Campos, J. and Ericsson, N., 1999. "Constructive data mining: modeling consumers expenditure in Venecuela". *Econometrics Journal*, 2 (2), 226-240.

Cerovac, S., 2005. "Novi kompozitni pokazatelji za hrvatsko gospodarstvo: prilog razvoju domaćeg sustava cikličkih pokazatelja" [online]. *Istraživanja*, 1-16. Zagreb: Hrvatska narodna banka. Dostupno na: [<http://hidra.srce.hr/arhiva/68/2445/www.hnb.hr/publikac/istrazivanja/i-016.pdf>].

Dreger, C. and Schumacher, C., 2005. "Out-of-sample Performance of Leading Indicators for the German Business Cycle – Single vs Combined Forecasts". *Journal of Business Cycle Measurement and Analysis*, 2 (1), 71-88

Enders, W., 1995. *Applied Econometric Time Series*. New York: John Wiley and Sons, Inc.

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

Granger, C. W. J., 1969. "Investigating Causal Relations by Econometric Methods and Cross-Spectral Methods". *Econometrica*, 37 (3), 424-438.

Granger, C. W. J., 1988. "Some Recent Developments in Concept of Causality". *Journal of Econometrics*, 39, 813-836.

Granger, C. W. J., Huang, W.-N. and Yang, C.-W., 2000. "A bivariate causality between stock prices and exchange rates: evidence from the recent Asian flu". *The Quarterly Review of Economics and Finance*, 40, 337-354.

Green, R. G., 1993. "Business cycle indicators: upcoming revision of the composite indexes". *Survey of Current Business*, (October).

Jagrič, T., 2001. "Sistem vodilnih pokazateljev gospodarske aktivnosti za Slovenijo (SLOLEI)" *Prikazi in Analiz*, IX/2. Ljubljana: Banka Slovenije.

Jagrič, T., Boršič, D. and Strašek, S., 2003. "Leading indicators of aggregate activity of Slovenia" [online]. Prague: Center for Economic Research and Graduate Education and the Economics Institute. Available from: [<http://www.cerge-ei.cz/>].

Kaminsky, G., Lizondo, S. and Reinhart, C., 1997. "Leading Indicators of Currency Crises". *Policy Research Working Paper*, No. 1852. Washington D.C.: The World Bank.

Moore, G. H. and Shiskin, J., 1967. "Indicators of Business Expansions and Contractions". *Economica, New Series*, 35 (139), 335-336.

Nierhaus, W., 2000. *Currency Crises Indicators – The Signal Approach*. Mimeo. Munich: IFO Institute for Economic Research.

Reijer, den A. H. J., 2006. "The Dutch Business Cycle: Which Indicators Should We Monitor?". *DNB Working Papers*, No. 100. Amsterdam: Netherlands Central Bank.

Rousseau, P. D. and Vuthipadorn, 2005. "Finance, Investment and Growth: Time Series Evidence from 10 Asian Economies". *Journal of Macroeconomics*, 27 (1), 87-106.

Sander, H. and Kleimeier, S., 2003. "Contagion and Causality: an Empirical Investigation of Four Asian Crisis Episodes". *Journal of International Financial Markets, Institutions and Money*, 13 (2), 171-186.

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

USDC and BEA, 1977. *Handbook of Cyclical Indicators*. Washington, D.C.: Department of Commerce: Bureau of Economic Analysis.

Zarnowitz, V. and Boschan, C., 1975. "Cyclical Indicators: An Evaluation and New Leading Indexes" in: *Handbook of Cyclical Indicators*. Washington: U.S. Department of Commerce, BEA.

Zarnowitz, V., 1992. *Business Cycles: Theory, History, Indicators, and Forecasting*. Chicago: The University of Chicago Press.

**Katarina Bačić and Maruška Vizek: A Brand New CROLEI:
Do We Need a New Forecasting Index?**

Abstract

The aim of this paper is to determine whether the existing leading indicators system CROLEI (Croatian Leading Economic Indicators) and its result, the prognostic index CROLEI, forecast overall Croatian economic activity reliably. The need to evaluate the CROLEI system and the index stems from a modification of the barometric method, on which the system and the index are founded, in its application in Croatia. The evaluation of prognostic power involves constructing six alternative forecasting indices, which not only challenge the original CROLEI index, but also enable inter-comparisons of prognostic power. The construction of alternative forecasting indices also employs the barometric method. The authors then proceed to adjust more complex measures i.e. prognostic power evaluation matrix, in order to obtain credible prognostic power estimates. Prognostic power is also estimated using two regression models that allow for the forecasting of referent series and yield measures of prognostic power. The results of the two approaches indicate not only that the original CROLEI has by far the greatest prognostic power but also that it is able to forecast the turning points in the economic cycle with the highest probability.

Key words: CROLEI, prognostic indicator, barometric method, signaling method