

Dr. sc. Mirjana Čižmešija

Redovita profesorica
Sveučilište u Zagrebu
Ekonomski fakultet Zagreb
E-mail: mcizmesija@efzg.hr

POVEZANOST OČEKIVANE PROIZVODNJE I POKAZATELJA POUZDANJA POTROŠAČA U PRERAĐIVAČKOJ INDUSTRIJI EUROPSKE UNIJE

UDK / UDC: 659.113.25:65.012.2

JEL klasifikacija / JEL classification: C53, E32, D12

Izvorni znanstveni rad / Original scientific paper

Primljeno / Received: 30. ožujka 2017. / March 30, 2017

Prihvaćeno za tisak / Accepted for publishing: 21. lipnja 2017. / June 21, 2017

Sažetak

Ankete pouzdanja poduzeća i potrošača (engl. Business and Consumer Surveys, BCS) koriste se kao izvor podataka za ekonomske analize i prognoze. U dostupnim dosadašnjim istraživanjima ispitivana je povezanost varijabli i pokazatelja BCS-a, s jedne strane, i makroekonomskih varijabli, s druge strane. Poznato je da se temeljem kompozitnih pokazatelja BCS-a može predvidjeti smjer promjene referentnih makroekonomskih varijabli i do nekoliko mjeseci unaprijed. U ovom radu ispituje se povezanost ocjena i očekivanja potrošača s očekivanjima menadžera u prerađivačkoj industriji. U radu se ispituje hipoteza da su Pokazatelj pouzdanja potrošača (engl. Consumer Confidence Indicator, CCI) i očekivana proizvodnja menadžera (engl. Production Expectation, PE) pozitivno korelirane varijable. Pritom se ispituje može li CCI biti prethodeći pokazatelj PE-u. Istraživanje je provedeno za Europsku uniju (EU), Europodručje (EA) i Republiku Hrvatsku (RH). Uočeno je da su očekivanja i ocjene potrošača, (sažete u CCI) i PE od strane menadžera u prerađivačkoj industriji statistički značajno pozitivno visoko korelirane varijable i imaju približno isti smjer promjene u analiziranom vremenu te pokazuju sličnu osjetljivost na poremećaje u gospodarstvu.

Ključne riječi: ankete pouzdanja poduzeća i potrošača, Pokazatelj pouzdanja potrošača, očekivana proizvodnja, konfuzijska matrica, korelacija pomičnog okvira.

1. UVOD

Ankete pouzdanja poduzeća i potrošača (BCS) su, u osnovi, kvalitativna istraživanja koja se provode kontinuirano mjesečno u skladu s harmoniziranom metodologijom Europske komisije. Ankete pouzdanja poduzeća (BS) provode se na uzroku menadžera u četiri sektora: prerađivačka industrija, građevinarstvo, uslužni sektor i trgovina na malo, dok se ankete pouzdanja potrošača (CS) provode na uzorku potrošača. Varijable BCS-a su uglavnom kvalitativne varijable izražene kao ocjene i očekivanja menadžera i potrošača o prodajnim cijenama, stanju zaliha, narudžbama, proizvodnji, zaposlenosti, štednji i sl. Prema europskoj harmoniziranoj metodologiji, ove se ocjene i očekivanja odabranim statističko-analitičkim metodama prevode u numeričke pokazatelje.

BCS pokazatelji se uobičajeno koriste kao prethodeći (vodeći) ili koincidentni pokazatelji za više makroekonomskih varijabli kao što su bruto domaći proizvod (BDP), industrijska proizvodnja, prometu trgovini na malo, nezaposlenost, izvoz, cijene, štednja i dr. Ovaj rad se temelji na pionirskom empirijskom istraživanju prediktivnih svojstava rezultata anketa pouzdanja potrošača (CS) u ocjenjivanju i predviđanju promjena u očekivanjima menadžera. Za razliku od dosadašnjih istraživanja, ovdje se povezuju dva, po metodološkim osnovama, slična istraživanja s ciljem ispitivanja postoji li statistički značajna povezanost između ekonomskog sentimenta potrošača i očekivane proizvodnje menadžera u prerađivačkoj industriji. Nadalje, cilj je ispitati ima li ekonomski sentiment potrošača, mjeren CCI-em, svojstvo prethodećeg pokazatelja u predviđanju očekivanja menadžera, te ukoliko ima, za koje vrijeme prethodjenja se očituje to svojstvo?

Varijable u mjesečnim istraživanjima u prerađivačkoj industriji su: proizvodnja u prethodna tri mjeseca, očekivana proizvodnja u sljedeća tri mjeseca, ocjena ukupnih narudžbi, ocjena narudžbi iz inozemstva, ocjena zaliha gotovih proizvoda, očekivane prodajne cijene i zaposlenost tvrtke u sljedeća tri mjeseca. Varijable u mjesečnim istraživanjima potrošača su: financijska situacija u posljednjih dvanaest mjeseci, financijska situacija u sljedećih dvanaest mjeseci, opća ekonomska situacija u posljednjih dvanaest mjeseci, opća ekonomska situacija u sljedećih dvanaest mjeseci, trend cijena u proteklih dvanaest mjeseci, trend cijena u sljedećih dvanaest mjeseci, očekivana nezaposlenost u sljedećih dvanaest mjeseci, ostvarena kupnja, kupnja u sljedećih dvanaest mjeseci, štednja u sljedećih dvanaest mjeseci i ocjena financijske situacije kućanstva (European Commission, 2016).

Sve varijable u BS-u su uglavnom kvalitativne s približno istim načinom navođenja modaliteta („porast“, „nemijenjanje“, „smanje“, „više nego dovoljno“, „dovoljno“, „nedovoljno“ i sl.). Modaliteti varijabli u CS-u su: „značajno poboljšanje“, „malo poboljšanje“, „ne mijenjanje“, „malo pogoršanje“, „značajno pogoršanje“, „ne znam“ (European Commission, 1997; Čizmešija, 2008). Za svako pitanje (varijablu) u istraživanju, izračunava se saldo. Saldo je razlika ponderiranih relativnih frekvencija pozitivnih i negativnih odgovora na

postavljeno pitanje. Ponderacijski sustav se uglavnom primjenjuje u BS-u gdje su ponderi određeni brojem zaposlenih i/ili ukupnim prihodom tvrtke. Kako bi se rezultati istraživanja, izraženi kao salda, agregirali, izračunavaju se kompozitni pokazatelji. Prema europskoj harmoniziranoj metodologiji BCS-a (European Commission, 1997; European Commission, 2016) Pokazatelj pouzdanja potrošača (CCI) je jednostavna aritmetička sredina sezonski prilagođenih salda četiriju varijabli CS-a: financijska pozicija kućanstva, opća ekonomska situacija, očekivana nezaposlenost (sa suprotnim predznakom) i štednja u sljedećih dvanaest mjeseci.

Salda i pojedinačni pokazatelji pouzdanja, odnosno kompozitni pokazatelji koriste se u tumačenju i predviđanju promjena u gospodarstvu. Uvažavajući primarni kvalitativni karakter ovih istraživanja, naglasak je na praćenju i predviđanju, prije svega, smjera promjene referentne serije, a manje intenziteta njezine promjene. Pritom je važno ispitati ne samo povezanost između BCS pokazatelja i ostalih makroekonomskih varijabli, već i između ekonomskog raspoloženja menadžera i potrošača, odnosno između rezultata dvaju srodnih istraživanja provedenih na različitim jedinicama ispitivanja.

Istraživanje je provedeno u dva dijela, a rad je podijeljen u pet poglavlja. U prvom dijelu se prezentira teorijsko određenje BCS-a i pregled dosadašnjih istraživanja (prvo i drugo poglavlje rada). U drugom dijelu su dani rezultati empirijskog istraživanja, tumačenje istih te su izvedeni zaključci. S ciljem prezentiranja postojanja i karaktera povezanosti CCI-a i PE-a za različite pomake u vremenu (prethođenje) primijenjene su odabrane statističke metode, što je prikazano u trećem poglavlju rada. Smjer promjene varijabli od interesa za istraživanje analiziran je konfuzijskom matricom i konfuzijskim omjerom. Kako bi se ispitalo je li povezanost između analiziranih varijabli stabilna u analiziranom periodu, izračunani su koeficijenti korelacije pomičnog okvira. Empirijsko istraživanje provedeno je za EU u cjelini, za EA, te posebno za RH. Glavni rezultati i tumačenje istih dani su u četvrtom poglavlju rada, a zaključna razmatranja, ograničenja provedenog istraživanja i planovi za buduća istraživanja nalaze se u petom poglavlju.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Poznato je da su BCS podaci u EU i EA, kao i u pojedinim zemljama članicama EU, korisni i često primjenjivi u makroekonomskim analizama i prognozama. Njihova prediktivna svojstva, posebno u predviđanju smjera promjene referentnih varijabli imaju vrlo važnu ulogu u kreiranju makroekonomske politike (Claveria, 2005; Gayer, 2005). Osim toga, ti su podaci raspoloživi u realnom vremenu, prije objave podataka o istim varijablama od strane službene statistike.

Veliki broj znanstvenika i istraživača fokusirao je svoja empirijska i teorijska istraživanja na utvrđivanje i mjerenje korelacije između ekonomske

osjetljivosti menadžera i potrošača s jedne strane, i gospodarskog okruženja s druge strane (Altin i Uysal, 2014; Gajewski, 2014; Mendicino i Punzi, 2013; Bruno, 2012 i dr.). Sveprisutna pitanja su: jesu li stvarni trendovi u gospodarstvu i ekonomska osjetljivost menadžera i potrošača međusobno povezani i može li se temeljem BCS podataka predviđati promjene u poslovnim ciklusima. U nastavku se ističu neka od novijih istraživanja teme od interesa.

Kuzmanovic i Sanfey (2013.) ispitivali su upotrebu rezultata anketa potrošača u predviđanju realnih varijabli u Hrvatskoj. Također, korištenjem europskih i američkih podataka, Ferreret et al. (2016.) ispitivali su ulogu CCI u predviđanju gospodarske stabilnosti. Uočili su, analizirajući dvanaest europskih zemalja, da povezanost između burzovnih kretanja i CCI-a postoji, ali da je znatno oslabila „pucanjem“ cjenovnog mjehura (engl. dot-com bubble).

Povjerenje potrošača i prinos na burzovnim tržištima istraživali su Salhin, A. et al. (2016). Zaključili su da povjerenje potrošača ne utječe na prinose na burzovnom tržištu. Povjerenje potrošača i rast potrošnje istraživali su Ng i Wright (2016). Koristili su se pokazateljima povjerenja potrošača i došli do zaključka da vijesti i najave o određenim makroekonomskim promjenama mogu dovesti do značajnih promjena u mjerama povjerenja potrošača.

Postojanje dugoročne povezanosti između pouzdanja potrošača i gospodarskog rasta u odabranim europskim zemljama empirijski su istraživali Ul Islam i Mumtaz (2016.). Čižmešija i Erjavec (2016.) u svojem su radu analizirale mogućnost uporabe BCS pokazatelja u predviđanju vjerojatnosti ekspanzije u Hrvatskoj. Pozitivni predznaci procijenjenih parametara u ekonometrijskim modelima predlagali su da vjerojatnost ekspanzije raste s porastom vrijednosti pokazatelja.

U analizi odrednica inflacije osam novih članica EU koje još uvijek nisu članice Europskog područja, Globan et al. (2016.) su, između ostaloga, u empirijsko istraživanje uključili CS pitanje o očekivanoj inflaciji u sljedećoj godini.

Kurnoga i Čižmešija (2016.) analizirale su povezanost između povjerenja potrošača i uvjeta života. Temeljem odabranih varijabli CS-a izračunale su novi pokazatelj financijskih teškoća kućanstava i usporedile ga s odabranim mjerama Europske statistike o dohotku i uvjetima života (EU-SILC mjerama). Pokazale su da spomenuti CS pokazatelj ima vrlo sličnu krivulju kretanja kao i odbrane EU-SILC varijable, što znači da se ocjene i očekivanja potrošača čak mogu upotrijebiti kao proxy varijable odabranim varijablama u EU-SILC-u.

3. METODOLOGIJA

Empirijski dio istraživanja proveden je na mjesečnim sezonski prilagođenim podacima BCS-a za EU, EA i RH. Podaci za EU i EA odnose se na razdoblje od siječnja 1985. do srpnja 2016. godine, a za RH od svibnja 2008. do

srpnja 2016. Vremenski niz podataka za RH je kraći zato što se spomenuta istraživanja u RH nisu ranije provodila. Podaci su objavljeni na službenim internetskim stranicama Europske komisije (European Commission, 2017). Dvije varijable su uključene u modele: Pokazatelj povjerenja potrošača (CCI) kao kompozitni pokazatelj anketa pouzdanja potrošača i očekivana proizvodnja u prerađivačkoj industriji (PE) izražena kao saldo.

Za različito vrijeme prethodjenja CCI-a PE-u izračunani su koeficijenti korelacije i ispitana njihova statistička značajnost. Kako bi se ispitala stabilnost povezanosti između analiziranih varijabli u promatranom razdoblju, izračunani su koeficijenti korelacije pomičnog okvira (engl. *rollingwindow correlation coefficients*). Zbog primarno kvalitativnog karaktera BCS-a, u ispitivanju prediktivnog svojstva varijable i kompozitnog pokazatelja, naglasak je stavljen na uspješnost predviđanja smjera promjene. U tu svrhu korišteni su: konfuzijska matrica, konfuzijski omjer, omjer točnosti klasificiranja, pokazatelj osjetljivosti i pokazatelj specifičnosti (Hassouna et al., 2015).

Kako bi se ispitala pretpostavka o neovisnosti planiranog i ostvarenog smjera promjene PE-a primijenjen je Hi-kvadrat test neovisnosti kvalitativnih varijabli u tablici kontingencne. Naime, informacije o prognoziranim i ostvarenim promjenama smjera analizirane pojave u vremenu uobičajeno se zapisuju u konfuzijskoj matrici (engl. *confusion matrix*), kako je dano u tablici 1.

Tablica 1.

Konfuzijska matrica BCS-a (frekvencije izražene apsolutno)

Prognoza	Realizacija		Ukupno
	Porast	Smanjenje	
Porast	f_{uu}	f_{ud}	$f_{u.}$
Smanjenje	f_{du}	f_{dd}	$f_{d.}$
Ukupno	$f_{.u}$	$f_{.d}$	n

Izvor: Čižmešija i Sorić, 2016, str. 211.

Konfuzijska matrica služi za vizualizaciju informacija o klasifikaciji predviđenih i realiziranih promjena varijable i kao osnova za provjeru točnosti predviđanja smjera promjene. Uvažavajući osnovne karakteristike BCS-a, analiza konfuzijske matrice je jedna od najčešće korištenih metoda mjerenja uspješnosti predviđanja (Čižmešija i Sorić, 2016).

Elementi konfuzijske matrice tumače se na sljedeći način: f_{uu} - broj prognoziranih povećanja koja su se zaista i realizirala, f_{ud} - broj prognoziranih

povećanja i realiziranih smanjenja, f_{du} - broj prognoziranih smanjenja i realiziranih povećanja i f_{dd} - broj prognoziranih smanjenja koja su se i realizirala kao smanjenja. Frekvencije u marginalnom stupcu tablice su: $f_{.u}$ - ukupan broj prognoziranih povećanja i $f_{.d}$ - ukupan broj prognoziranih smanjenja. Analogno tome se tumače i frekvencije u marginalnom retku: $f_{.u}$ - ukupan broj realiziranih povećanja i $f_{.d}$ - ukupan broj realiziranih smanjenja analizirane pojave (varijable).

Elementi konfuzijske matrice na dijagonali (f_{uu} i f_{dd}) pokazuju ukupan broj uspješno prognoziranih promjena smjera varijable u uzorku veličine n . Proporcija uspješnih predviđanja smjera promjene varijable od interesa (u radu PE) naziva se omjer točnosti klasificiranja (engl. *Classification Accuracy Rate*, *CAR*) i izračunava se izrazom 1.

$$CAR = \frac{1}{n}(f_{uu} + f_{dd}) \quad (1)$$

Konfuzijski omjer (engl. *Confusion Rate*, *CR*) je proporcija neispravnih prognoza, odnosno relativni udio neispravnih prognoza u ukupnom broju opažanja n . Izračunava se izrazom 2.

$$CR = \frac{1}{n}(f_{ud} + f_{du}), \quad (2)$$

pri čemu je f_{ud} broj predviđenih porasta i realiziranih smanjenja dok je f_{du} broj predviđenih smanjenja i realiziranih porasta pojave. U oba primjera prognoza smjera nije ispravna.

Pokazatelj senzitivnosti (engl. *Sensitivity*) je relativni udio porasta varijable koji su bili uspješno predviđeni u ukupnom broju porasta promatrane varijable (izraz 3). Pokazatelj specifičnosti (engl. *Specificity*) je relativni udio smanjenja varijable koja su bila ispravno predviđena u ukupnom broju smanjenja (izraz 4).

$$Sensitivity = \frac{f_{uu}}{f_{.u}} \quad (3)$$

$$Specificity = \frac{f_{dd}}{f_{.d}} \quad (4)$$

Odgovarajuće vjerojatnosti utvrđene temeljem tablice 1, izražene kao relativne frekvencije proporcije, dane su u tablici 2.

Tablica 2.

Vjerojatnosti (proporcije) u konfuzijskoj matrici BCS-a

Prognoza	Realizacija		Ukupno
	Porast	Smanjenje	
Porast	p_{uu}	p_{ud}	$p_{u.}$
Smanjenje	p_{du}	p_{dd}	$p_{d.}$
Ukupno	$p_{.u}$	$p_{.d}$	1

Izvor: prema Čizmešija i Sorić, 2016, str. 211.

U tablici 2 p_{uu} je proporcija, odnosno relativni udio prognoziranih i ostvarenih porasta pojave u ukupnom broju opažanja, p_{ud} je proporcija prognoziranih porasta i realiziranih smanjenja, p_{du} je proporcija prognoziranih smanjenja i realiziranih porasta i p_{dd} je proporcija prognoziranih i realiziranih smanjenja pojave. Spomenute proporcije su zajedničke vjerojatnosti. Marginalni stupac tablice 2 sadrži proporcije prognoziranih povećanja ($p_{u.}$) i prognoziranih smanjenja ($p_{d.}$) pojave u ukupnom broju opažanja n . Marginalni redak sadrži proporcije realiziranih porasta ($p_{.u}$) i realiziranih smanjenja ($p_{.d}$) analizirane pojave u ukupnom broju opažanja n . Proporcije u marginalnom retku i marginalnom stupcu su marginalne vjerojatnosti.

Dvije su varijable u tablici kontingence nezavisne ako je zajednička vjerojatnost (u svakom pojedinačnom polju tablice) jednaka produktu pripadajućih marginalnih vjerojatnosti (McClave et al., 2014). Zaključivanje o povezanosti planiranih i realiziranih promjena smjera pojave, odnosno o uspješnosti prognoza provodi se na temelju rezultata Hi-kvadrat testa o nezavisnosti obilježja u tablici kontingence dimenzije 2x2 (Čizmešija i Sorić, 2016). Hipoteze testa dane su izrazom 5.

$$\begin{aligned}
 H_0 \dots p_{ij} &= p_{i.} \cdot p_{.j} \\
 H_1 \dots \exists p_{ij} &\neq p_{i.} \cdot p_{.j}, \quad \forall i, j
 \end{aligned}
 \tag{5}$$

pri čemu su $p_{ij}, p_{i.}, p_{.j}, i=1,2, j=1,2$ zajedničke vjerojatnosti (i, j), $i=1,2; j=1,2$ dvodimenzionalne slučajne varijable te marginalne vjerojatnosti u stupcu i u retku. Frekvencije koje se očekuju po nultoj hipotezi o nezavisnosti varijabli su očekivane frekvencije e_{ij} . Nulta hipoteza sadrži tvrdnju da su prognozirane i realizirane promjene smjera nezavisne, dok alternativna sadrži suprotnu tvrdnju da prognozirane i realizirane promjene smjera nisu nezavisne.

Test veličina je empirijski χ^2 koji se izračunava po izrazu 6.

$$\chi^2 = \sum_{i=1}^2 \sum_{j=1}^2 \frac{(f_{ij} - e_{ij})^2}{e_{ij}}, \quad (6)$$

pri čemu su e_{ij} očekivane frekvencije prema hipotezi o nezavisnosti prognoze i realizacije i izračunavaju se po izrazu 7.

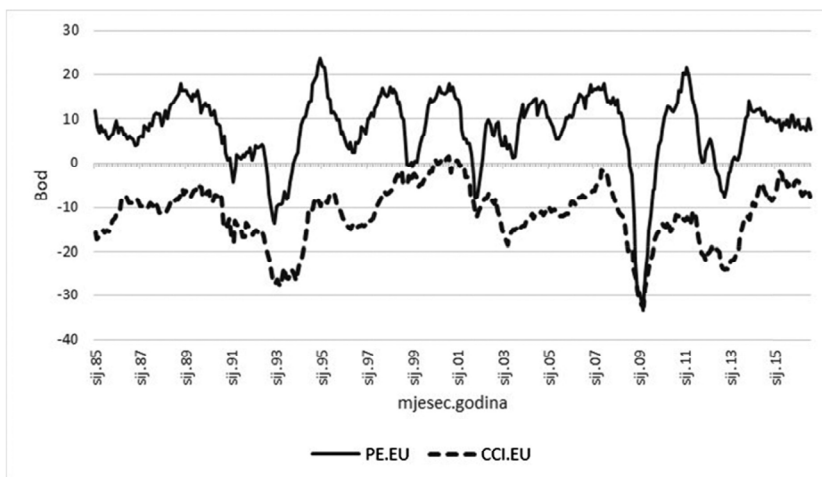
$$e_{ij} = \frac{f_{i.} \cdot f_{.j}}{n}, \quad i = 1, 2; \quad j = 1, 2 \quad (7)$$

Teorijska vrijednost χ^2 određuje se za razinu značajnosti testa α i za jedan stupanj slobode jer je $(r-1)(c-1) = (2-1)(2-1) = 1$, pri čemu je r - broj redaka i c - broj stupaca u tablici kontingence. Ona dijeli područje neodbacivanja nulte hipoteze od područja njezinog odbacivanja. Ako je empirijski χ^2 manji od teorijskog, nulta hipoteza se ne odbacuje. Isto se zaključuje ako je empirijska razina signifikantnosti (p -vrijednost) veća od teorijske razine signifikantnosti α .

Ako su prognozirane i realizirane promjene smjera analizirane varijable nezavisne, nije uputno koristiti odabrani model prognoziranja smjera promjene pojave jer on nije reprezentativan. U tom slučaju i konfuzijski omjer poprima relativno veliku vrijednost u odnosu prema omjeru uspješno provedenih prognoza.

4. RASPRAVA

Dinamika dviju analiziranih varijabli PE i CCI na razini EU u promatranom razdoblju od siječnja 1985. do srpnja 2016. godine prikazana je na slici 1.



Slika 1. PE i CCI u EU

Izvor: *Izrada autorice po podacima na:*
http://ec.europa.eu/economy_finance/db_indicators.

Lako se može uočiti da obje varijable imaju vrlo sličnu dinamiku kretanja. Najmanje vrijednosti objiju varijabli zabilježene su početkom 1993. i 2009. godine. Ako se ima na umu da BCS varijable i BCS pokazatelji imaju svojstvo predviđanja smjera kretanja referentnih serija (npr. industrijske proizvodnje, BDP-a i dr.) i ako se zna da se po promjenama BCS varijabli mogu ispravno predvidjeti promjene u makroekonomskim varijablama do šest mjeseci unaprijed, tada se zna da su male vrijednosti PE-a i CCI-a u 1993. i u 2009. godini signalizirale negativne trendove (recesiju) u europskoj ekonomiji, koji su se zaista i ostvarili.

Menadžeri i potrošači su uočili, odnosno ispravno predvidjeli, inflaciju uvođenjem Eura kao valute plaćanja u siječnju 1999. godine. Posebno teške godine bile su 2000. i 2001. Euro je bio relativno slaba valuta kroz sljedeće tri godine. Dakle, inflacija i recesija u EU ispravno su prepoznani, odnosno predviđeni temeljem podataka BCS-a.

Nasuprot tome, najveće vrijednosti PE-a i CCI-a mogu se uočiti 1995. i 2011. godine, što znači da je tada optimizam menadžera i potrošača bio dominantan, što je, uvažavajući prediktivna svojstva BCS pokazatelja, bio signal povoljnih kretanja sljedećih tri do šest mjeseci.

Koeficijenti korelacije između varijabli PE i CCI za različite vremenske pomake prikazani su u tablici 3. Može se uočiti da su spomenute dvije varijable pozitivno i najjače povezane u istom vremenu, bez prethodjenja. Koeficijent korelacije je 0.7264. Statistički je značajan na razini signifikantnosti 5 %. To znači da su očekivanja europskih menadžera o proizvodnji u sljedeća tri mjeseca i ocjene potrošača statistički značajno korelirane, odnosno da su PE i CCI koincidentni pokazatelji. Ovaj zaključak jednim je dijelom posljedica povezanosti analiziranih varijabli s ostalim makroekonomskim varijablama koje su utjecale na ponašanje menadžera i potrošača, ali je i potvrda kvalitete BCS-a i pouzdanosti tako dobivenih rezultata. Pritom treba imati na umu da su, kao što je već istaknuto, BCS podaci raspoloživi u stvarnom vremenu, prije podataka službene statistike što im dodatno povećava važnost uključivanja umakroekonomske analize i predviđanja.

Tablica 3.


Koeficijenti korelacije između PE i CCI u Europskoj uniji

Varijabla	CCI(0)	CCI(-1)	CCI(-2)	CCI(-3)	CCI(-4)	CCI(-5)	CCI(-6)
Koeficijent korelacije	0.72604*	0.69982*	0.65521*	0.59877*	0.53830*	0.46937*	0.39464*
<i>p</i> -vrijednost	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000
Varijabla	CCI(-7)	CCI(-8)	CCI(-9)	CCI(-10)	CCI(-11)	CCI(-12)	
Koeficijent korelacije	0.32117*	0.24966*	0.17858*	0.10705*	0.04308	-0.01698	
<i>p</i> -vrijednost	0.00000	0.00000	0.00060	0.04040	0.41050	0.7457	

*Napomena: *signifikantno na razini 5% signifikantnosti*

Izvor: izračun autorice

Stabilnost povezanosti dviju analiziranih varijabli ispitana je koeficijentima korelacije pomičnog okvira. Centrirani dvogodišnji i četverogodišnji koeficijenti korelacije pomičnog okvira (24 i 48 opažanja) prikazani su na slici 2.



Slika 2. Koeficijenti korelacije pomičnog okvira između PE i CCI u EU

Izvor: Izrada autorice po podacima na:

http://ec.europa.eu/economy_finance/db_indicators

Uočava se da su koeficijenti korelacije između potrošačkih ocjena i očekivanja sažetih u CCI-u, s jedne strane i očekivane proizvodnje menadžera u prerađivačkoj industriji EU, s druge strane, relativno stabilni, pozitivni i na visokoj razini (oko 0.8) tijekom gotovo cijelog razdoblja promatranja. Nestabilnost je uočena kroz niže vrijednosti koeficijenata u razdobljima koja su istaknuta i na slici 1., kada su bili prisutni poremećaji u gospodarstvu kao što su inflacija, nedavna recesija i „pucanje“ cjenovnog mjehura (1998., 1999. i 2005. godine).

U tablici 4. dana je konfuzijska matrica broja realiziranih i predviđenih promjena PE na bazi promjena CCI (u istom vremenu, bez prethođenja) pošto su spomenute dvije varijable pozitivno, statistički značajno i najjače povezane u istom vremenu, bez prethođenja (kako je dano u tablici 3).

Tablica 4.

Konfuzijska matrica: PE i CCI (u istom vremenu)

Prognoza	Realizacija		Ukupno
	Porast	Smanjenje	
Porast	121 (0.34181)	66 (0.18644)	187 (0.52825)
Smanjenje	66 (0.18644)	101 (0.28531)	167 (0.47175)
Ukupno	187 (0.52825)	167 (0.47175)	354 (1.00000)

Napomena: U 24 primjera jedna od promjena je bila jednaka nuli. Ti slučajevi su isključeni iz analize. Proporcije (vjerojatnosti) su dane u zagradama.

Izvor: izračun autorice

Od ukupno 354 mjesečna opažanja, u 34,18 % slučajeva je, temeljem promjene CCI, predviđen i realiziran porast PE ($p_{uu}=0.34181$). Također je u 28,53 % slučajeva predviđeno i realizirano smanjenje PE-a ($p_{dd}=0.28531$). Promjene su predviđene i realizirane u istom vremenu.

Prema izrazima (1) i (2) izračunani su CAR i CR za različite pomake u vremenu. Rezultati su prikazani u tablici 5.

U najviše slučajeva, (63 %) smjer promjene očekivane proizvodnje (PE) bio je jednak kao i smjer promjene CCI u istom vremenu ($CAR(0)=0.62712$). Pokazatelj senzitivnosti (izračunan po izrazu 3) iznosi 0.6470665 što znači da je 65% svih porasta PE ispravno predviđeno porastom CCI u istom vremenu. Pokazatelj specifičnosti (izračunan po izrazu 4) je 0.60479 što znači da je 60% svih smanjenja PE ispravno predviđeno smanjenjem CCI. Dobiveni rezultati upućuju na zaključak da su ocjene i očekivanja potrošača izražene kroz CCI značajno povezane u istom vremenu, bez prethodjenja.

Tablica 5.

Omjer točnosti klasificiranja (CAR) i konfuzijski omjer (CR) u EU

Pomak	CAR	CR	Pomak	CAR	CR
0	0,62712	0,37288	7	0,51297	0,48703
1	0,56941	0,43059	8	0,47110	0,52890
2	0,60227	0,39773	9	0,53043	0,46957
3	0,52137	0,47863	10	0,47093	0,52907
4	0,56125	0,43875	11	0,46957	0,53043
5	0,53143	0,46857	12	0,47953	0,52047
6	0,48276	0,51724			

Izvor: izračun autorice

Kako bi se ranije doneseni zaključci dodatno potvrdili, proveden je Hi-kvadrat test o nezavisnosti varijabli u tablici kontingence (prema tablici 4). Budući da je empirijski Hi-kvadrat 22,45, a teorijski Hi-kvadrat, za jedan stupanj slobode i razinu signifikantnosti testa 5 % ($\alpha = 0,05$), iznosi 3,8146 ($\chi_{0,05}^2 = 3.8146$), nulta hipoteza o neovisnosti se odbacuje. Temeljem toga se može zaključiti da su predviđene (po CCI-u) i ostvarene promjene PE u Europskoj prerađivačkoj industriji zavisne varijable. Jednak zaključak donosi se temeljem empirijske razine signifikantnosti (p -vrijednosti) jer je p -vrijednost jednaka nuli ($p \approx 0,00$), odnosno kao takva je manja od teorijske razine signifikantnosti 0,05.

Istovrsna analiza provedena je za EA i RH. Koeficijenti korelacije između PE i CCI za EA dani su u tablici 6, a za RH u tablici 7.

Tablica 6.

Koeficijenti korelacije između PE i CCI u EA

Varijabla	CCI(0)	CCI(-1)	CCI(-2)	CCI(-3)	CCI(-4)	CCI(-5)	CCI(-6)
Koeficijent korelacije	0,75655*	0,72419*	0,67546*	0,61544*	0,55203*	0,48171*	0,40491*
p -vrijednost	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
Varijabla	CCI(-7)	CCI(-8)	CCI(-9)	CCI(-10)	CCI(-11)	CCI(-12)	
Koeficijent korelacije	0,33003*	0,25725*	0,18651*	0,11485*	0,05112	-0,00751	
p -vrijednost	0,00000	0,00000	0,00030	0,02780	0,3288	0,88590	

*Napomena: *signifikantno na razini 5% signifikantnosti*

Izvor: izračun autorice

Tablica 7.

Koeficijenti korelacije između PE i CCI u RH

Varijabla	CCI(0)	CCI(-1)	CCI(-2)	CCI(-3)	CCI(-4)	CCI(-5)	CCI(-6)
Koeficijent korelacije	0,75279*	0,70294*	0,67618*	0,64012*	0,62600*	0,58910*	0,55372*
p -vrijednost	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
Varijabla	CCI(-7)	CCI(-8)	CCI(-9)	CCI(-10)	CCI(-11)	CCI(-12)	
Koeficijent korelacije	0,47764*	0,38994*	0,31911*	0,25851*	0,20659	0,12122	
p -vrijednost	0,00000	0,00019	0,00259	0,01562	0,05488	0,26337	

*Napomena: *signifikantno na razini 5% signifikantnosti*

Izvor: izračun autorice

Zaključci su vrlo slični onima za EU. Najveći, statistički signifikantan, pozitivan koeficijent korelacije zabilježen je između PE i CCI u istom vremenu (bez prethodjenja). On za EA iznosi 0,75655, dok je isti za RH vrijednosti

0,75279. Budući da su koeficijenti korelacije najveći u istom vremenu (bez prethođenja) zaključuje se da su PE i CCI koincidentni pokazatelji i za EA i za RH.

5. ZAKLJUČAK

Veliki broj teorijskih istraživanja, temeljen na BCS podacima, usredotočen je na ispitivanje i analiziranje moguće povezanosti između BCS varijabli i/ili pokazatelja s ekonomskim i financijskim pokazateljima kao što su BDP, inflacija, burzovni pokazatelji, izvoz i dr. Mnoga od njih imaju važan znanstveni i stručni doprinos. Dobro je poznato da kompozitni pokazatelji BCS-a u prerađivačkoj industriji, u građevinarstvu, trgovini na malo, uslužnom sektoru i među potrošačima imaju prediktivna svojstva u predviđanju smjera promjene referentnih makroekonomskih varijabli s prethođenjem od nekoliko mjeseci. To znači da ekonomski sentiment potrošača i menadžera, izražen kao numerički pokazatelj, može uspješno biti uključen u ekonomske analize i prognoze.

Istraživanje provedeno u ovom radu je iskorak u objašnjenju povezanosti između ocjena i očekivanja potrošača i očekivanja menadžera u prerađivačkoj industriji u Europskoj uniji, Europodručju i u Hrvatskoj. Očekivana proizvodnja menadžera u prerađivačkoj industriji i potrošačke ocjene financijskog položaja kućanstva, opće gospodarske situacije, očekivane nezaposlenosti i štednje u sljedećih dvanaest mjeseci (prezentirane kroz CCI) su visoko, statistički značajno, pozitivno korelirane varijable u istom vremenu, bez prethođenja. Statistički test nezavisnosti varijabli u tablici kontingence pokazao je da su očekivanja menadžera i potrošački sentiment sinkronizirani. To su koincidentni pokazatelji. Povezanost ta dva fenomena je ipak slabija u razdobljima ekonomskih poremećaja kao što su inflacija, recesija i sl. Zato je hipoteza rada prihvaćena, a odgovori na ranije postavljena pitanja su sljedeći: Europski CCI i očekivanja menadžera o njihovoj industrijskoj proizvodnji su snažno pozitivno povezani. Pri tome je CCI koincidentni, ali ne i prethodeći pokazatelj očekivanoj proizvodnji u prerađivačkoj industriji. Jednako tako se može zaključiti da su ankete potrošača značajne ne samo za makroekonomske analize i prognoze, već i za poslovno odlučivanje i upravljanje.

Istraživanje provedeno u ovom radu primarno je usredotočeno na Europsku uniju i Europodručje kao agregatne razine. Istraživana su prognostička svojstva CCI-a u predviđanju očekivane proizvodnje u prerađivačkoj industriji, ali ne i očekivane proizvodnje menadžera u predviđanju promjena sentimenta potrošača. Ova ograničenja će se uzeti u razmatranje u sljedećim istraživanjima koja se planiraju provesti po pojedinim zemljama članicama EU (odvojeno). Osim toga, uključivanjem psiholoških karakteristika menadžera i potrošača u statističke modele osiguralo bi se preciznije praćenje, objašnjavanje i predviđanje promjena u nacionalnim ekonomijama, kao i na razini Europske unije i Europodručja.

Napomena: Rad je financirala Hrvatska zaklada za znanost projektom broj IP-11-2013-3858.

LITERATURA

Altin, M. i Uysal, M. (2014). Economic sentiment indicator as a demand determinant. *Tourism Analysis*, Vol. 19, No. 5, pp. 581–597.

Bruno, G. (2012). Consumer confidence and consumption forecast: a non-parametric approach. MPRA, <https://mpra.ub.uni-muenchen.de/41312/> [2017/01/13]

Claveria, O, Pons, E. i Ramos, R. (2005). Business and Consumer Expectations and Macroeconomic Forecasts. *Proceedings of Conference on Survey data in Economics – Methodology and Applications*. Cess IFO, Munich: 1-20.

Čižmešija, M. (2008). *Konjunkturni testovi Europske unije i Hrvatske*. Privredni vjesnik, Zagreb.

Čižmešija, M. i Erjavec, N. (2016). Can Confidence indicators forecast the probability of expansion in Croatia? *Croatian Operational Research Review*, Vol 7, No. 1, pp. 97-107.

Čižmešija, M. i Sorić, P. (2016). *Statističke metode za poslovno upravljanje u programskom jeziku R*. Element, Zagreb.

European Commission (2017). Economic Databases; Business and Consumer Surveys, https://ec.europa.eu/info/business-economy-euro/indicators-statistics/economic-databases_en [2017/01/13]

European Commission (2016). The Joint Harmonised EU Programme of Business and Consumer Surveys, User guide, 03/2016. http://ec.europa.eu/economy_finance/db_indicators/surveys/documents/bcs_user_guide_en.pdf [2017/01/13]

European Commission (1997). The joint harmonised EU programme of Business and Consumer Surveys. Directorate-General for Economic and Financial Affairs.

Ferrer, E., Salaber, J. i Zalaewska, A. (2016). Consumer confidence indices and stock markets' melt down. *European Journal of Finance*, 22 (3), pp. 195-220.

Gajewski, P. (2014). Nowcasting Quarterly GDP Dynamics in the Euro Area – The Role of Sentiment Indicators. *Comparative Economic Research*, Vol. 17, No. 2, pp. 5-23.

Gayer, C. (2005). Forecast Evaluation of European Commission Survey Indicators. *Journal of Business Cycle Measurement and Analysis*, No. 2, pp. 157-183.

Globan, T., Arčabić, V. i Sorić, P. (2016). Inflation in New EU Member States: A Domestically or Externally Driven Phenomenon? *Emerging markets finance and trade*, Vol 52, No.1, pp. 154-168.

Hassouna, M, Tarhini, A., Elyas, T. i AbouTrab, M. S. (2015). Customer Churn in Mobile Markets: A Comparison of Techniques. *International Business Research*, Vol. 8, No. 6, pp. 224 -237.

Kurnoga, N. i Čižmešija, M. (2016). Can Consumer Survey produce a new Measure of Households' Financial Distress? *Croatian Operational Research Review*, Vol. 7, No. 2, pp. 189-200.

Kuzmanovic, M. i Sanfey, P. (2012). Can Consumer Confidence Data Predict Real Variables? Evidence from Croatia. *Croatian Economic Survey*, Vol. 15, No. 1, pp. 5-24.

Mendicino, C. i Punzi, M.T. (2013). Confidence and economic activity: the case of Portugal, <https://www.bportugal.pt/en> [2017/02/06]

McClave, J. T., Benson, G. P. i Sincich, T. (2014). *Statistics for business and Economics, 12th edition*. Prentice Hall, New York.

Ng, S. i Wright, H. (2016). The Predictive Content of High Frequency Consumer Confidence Data.

<http://www.columbia.edu/~sn2294/papers/confidence-07222016.pdf>
[2017/02/08]

Salhin, A., Sherif, M. i Jones, E. (2016). Managerial Sentiment, Consumer Confidence and Sector Returns. *International Review of Financial Analysis*, Vol. 47, pp. 24–38.

Ul Islam, T. i Mumtaz, M. N. (2016). Consumer Confidence Index and Economic Growth: An Empirical Analysis of EU Countries. *Euro Economica*, Vol. 35, No. 2 <http://journals.univ-danubius.ro/index.php/euroeconomica/article/view/3541/3685> [2017/02/06]

Mirjana Čizmešija, PhD

Full Professor
University of Zagreb
Faculty of Economics and Business Zagreb
E-mail: mcizmesija@efzg.hr

**THE RELATIONSHIP BETWEEN EXPECTED
PRODUCTION AND CONSUMER CONFIDENCE
INDICATOR IN THE EUROPEAN UNION
MANUFACTURING INDUSTRY*****Abstract***

Business and Consumer Surveys (BCS) are used as data source in economic analyses and forecasts. In available previous researches the correlation between variables and BCS indicators on the one hand, and macroeconomic variables, on the other hand, are investigated. Based on BCS composite indicators, the direction of changes of relevant macroeconomic variables can be predicted, up to several months in advance. In this paper the correlation between consumers' assessments and expectations and managers' expectations in manufacturing industry are investigated. The hypothesis that there is a positive correlation between the Consumer Confidence Indicator (CCI) and expected production (PE) is also tested. It is therefore examined if the CCI can be a leading indicator to PE. The research is conducted for the European Union (EU), Euro area (EA) and for the Republic of Croatia (RH). It has been noted that the consumers' expectations and assessments (summarized in CCI) and PE by managers in the manufacturing industry are positively highly correlated variables and have approximately the same direction of changes in the analysed period and showed a similar sensitivity to disruptions in the economy.

Keywords: *Business and consumer surveys, Consumer Confidence Indicator, expected production, confusion matrix, rolling window correlation*

JEL classification: *C53, E32, D12*