PREDVIĐANJE PROIZVODNJE, POVRŠINA I PRINOSA KROMPIRA U BOSNI I HERCEGOVINI

Nedeljković Miroslav¹

Vujić Jovana²

Sažetak: Cilj rada bio je da se primjenom kvantitativnog metoda istraživanja, odnosno analize trenda, kreira adekvatan model trenda kojim će moći da se predvidi proizvodnja krompira u Bosni i Hercegovini za trogodišnji period (2019–2021). Za predviđanje je korišćena dvadesetsedmogodišnja vremenska serija podataka (1992–2018), a rezultati istraživanja pokazuju da će površina i proizvodnja krompira u periodu predviđanja pokazati smanjenje, a da će prinos biti jedini proizvodni parametar krompira koji će pokazati tendenciju rasta u periodu trogodišnje predikcije. Dobijeni rezultati istraživanja mogu poslužiti u svrhu donošenja strateških odluka vezanih za razvoj ove grane poljoprivredne proizvodnje.

Ključne reči: predviđanje / proizvodnja / površina / prinos / trend / krompir / BiH

UVOD

Krompir je jedan od najintenzivnijih i najprofitabilnijih povrtarskih usjeva. Zahvaljujući širokim adaptivnim mogućnostima, visokoj

1 Univerzitet „Bijeljina“, Poljoprivredni fakultet, Pavlovića put bb, Bijeljina, Republika Srpska, Bosna i Hercegovina, e-mail: miroslavnedeljkovic2015@gmail.com

2 Univerzitet „Bijeljina“, Poljoprivredni fakultet, Pavlovića put bb, Bijeljina, Republika Srpska, Bosna i Hercegovina, e-mail: jovana.vujic.ubn@gmail.com

reproduktivnoj sposobnosti (5–30 puta) i dobroj nutritivnoj vrijednosti krtola, krompir se u svijetu uzgaja u preko 130 zemalja. (Poštić, 2013 str.1) Proizvodnja krompira ima veliki privredni značaj, kako u manje razvijenim, tako i u privredno visoko razvijenim zemljama. (Puškarić, 2007, str. 7) Prema istom autoru ova povrtarska kultura obezbjeđuje bazu za diverzifikaciju u proizvodnji velikog broja prerađevina, te podstiče zaposlenost i razvoj robne proizvodnje u poljoprivredi. Preko 85 različitih industrija koristi krompir kao sirovinu od koje se dobija više od hiljadu proizvoda (Vlahović, 2003, str. 8). Prema Maksimoviću i Bročiću (2005) profit koji je moguće ostvariti proizvodnjom konzumnog krompira, u ravničarskom rejonu, sa navodnjavanjem, iznosi 1.052 eura/ha.

U ukupnoj proizvodnji hrane, krompir zauzima značajno mjesto u Bosni i Hercegovini. To proizilazi iz činjenice da se u 2018. godini krompir u Bosni i Hercegovini gajio na 35.159 ha, te da je ostvario proizvodnju od 394.274 t, koja je od proizvodnje postignute u zemljama regiona (bivša SFRJ) bila manja samo od one koja je zabilježena u Srbiji iste godine (487.909 t). Najveći proizvođač krompira u svijetu je Kina, čija je proizvodnja u 2018. godini bila 90.259.155 tona, što je skoro jedna četvrtina (24,5%) svjetske proizvodnje u toj godini. (FAOSTAT, 2018)

Zbog privrednog i prehrambenog značaja koji ima, praćenje i predviđanje proizvodnje krompira mora imati veću ulogu. Prema Novkoviću i sar. (2010), analiza stanja i predviđanje mogu biti zasnovani na uređenom nizu podataka u jednakim vremenskim intervalima, odnosno na analizi vremenskih serija posmatranih pojava. Mutavdžić (2010) smatra da u tržišnim uslovima privređivanja, uspješna proizvodnja zavisi od praćenja, analize i predviđanja, rezultata i najvažnijih faktora koji utiču na nju.

Ranija istraživanja pojedinih autora bazirala su se na kvantitativnim modelima vremenskih serija gdje se predviđala proizvodnja povrća pa između ostalog i krompira. (Mutavdžić, 2010; Novković i sar., 2009; Mutavdžić i sar., 2011; Mutavdžić i sar., 2011a; Lazić, 2014; Ivanišević, 2015, Hossain and Abdulla, 2015).

Novković i saradnici (2012) kao i Mutavdžić i saradnici (2013) analizirali su i predvidjeli ponašanje proizvodnih karakteristika povrtarske proizvodnje u Republici Srpskoj do 2016. godine. Osim toga, pomenuti

autori su izvršili komparativnu analizu proizvodnje povrća u Srbiji i Republici Srpskoj. Hossain i Abdulla (2016) predviđaju proizvodnju krompira u Bangladešu do 2023. godine na osnovu prethodne vremenske serije podataka koristeći u tu svrhu ARIMA modele.

Predmet rada je analiza kretanja proizvodnje krompira u Bosni i Hercegovini sa ciljem stvaranja adekvatnog modela predviđanja proizvodnih pokazatelja ove povrtarske vrste. Dobijeni rezultati istraživanja mogli bi poslužiti prilikom donošenja strateških planova i odluka, a koji bi se ticali daljeg razvoja ove poljoprivredne grane.

METODOLOGIJA ISTRAŽIVANJA I IZVORI PODATAKA

Osim standardnog instrumentarijuma deskriptivne statistike (*prosječne vrijednosti, intervala varijacije, koeficijenta varijacije, i stope promjene*), korišćena je analiza trenda i to u svrhu predviđanja proizvodnje krompira za period 2019–2021. godine.

Model linearnog trenda dobijamo uz pomoć sledeće formule:

$$Y_t = \beta_0 + \beta_1 t + e_t$$

Model kvadratnog trenda dobijamo uz pomoć sledeće formule:

$$Y_t = \beta_0 + \beta_1 \times t + \beta_2 t^2 + e_t$$

Model eksponencijalnog trenda dobijamo uz pomoć sledeće formule:

$$Y_t = \beta_0 \times \beta_1^t \times e_t$$

Za izbor adekvatnog modela predviđanja koristile su se tri mjere tačnosti i to: srednja apsolutna procentna greška (MAPE), potom srednja apsolutna devijacija (MAD) i srednje kvadratno odstupanje (MSD). (Makridakis and Hibon, 2000; Goodwin and Lawton, 1999)

MAPE (eng. *Mean Absolute Percentage Error*) je metoda predviđanja koja se koristi u vremenskim serijama gdje se naročito posmatra periodičnost. Dobija se na osnovu sledeće formule:

$$\text{MAPE} = \frac{1}{n} \sum I(y_t - \hat{y}_t) / y_t \text{ I100}$$

MAD (eng. *Mean Absolute Deviation*) predstavlja disperzijsku metodu koja se stvara kao odstupanje modaliteta od reprezentativnog parametra.

Dobija se na osnovu sledeće formule:

$$MAD = \frac{1}{n} \sum |y_t - \hat{y}_t|$$

MSD (eng. *Mean Squared Deviation*) je srednje kvadratno odstupanje koje predstavlja matematičko očekivanje koliko dobro aritmetička sredina predstavlja dobijene rezultate do kojih se došlo. Dobija se na osnovu sledeće formule:

$$MSD = \frac{1}{n} \sum (y_t - \hat{y}_t)^2$$

Prema Karim i saradnici (2010) najniža vrijednost prethodnih mjera tačnosti predstavlja dobar pokazatelj izbora modela sa minimalnim greškama u predviđanju.

Podaci za dvadesetsedmogodišnju vremensku seriju podataka (1992-2018) proizvodnih pokazatelja krompira dobijeni su iz baze FAOSTAT-a a obrada je izvršena u statističkom programskom paketu MINITAB 17.1.

REZULTATI ISTRAŽIVANJA SA DISKUSIJOM

Iz tabele 1 vidimo da je prosječna površina pod krompirom u BiH za analizirani period bila 40.145 ha te da pokazuje tendenciju pada po stopi promjene od -0,49. Površine pod krompirom su imale relativno stabilno kretanje u posmatranom periodu mjereno koeficijentom varijacije (cv=12,21%). Za razliku od površina, proizvodnja krompira bilježi blagu tendenciju rasta za analizirani period i njena prosječna vrijednost za isti period iznosi 370.825 tona. Prinos krompira ima malo veću nestabilnost u svom kretanju u poređenju sa ostala dva proizvodna pokazatelja (cv=15,7%) i prosječno je na nivou od 9,31t/ha.

Tabela 1. *Dinamika kretanja proizvodnje krompira u BiH (1992-2018)*

Parametri proizvodnje	Prosjeak	Interval varijacije		Koef. Varijacije (%)	Stopa promjene (%)
		Min.	Max.		
Površina (ha)	40.145,07	34.175,0	53.000,0	12,21	-0,49
Proizvodnja (t)	370.825,37	255.000,0	458.615,0	14,62	0,81
Prinos (t/ha)	9,31	6,54	11,96	15,72	1,31

Izvor: Prema podacima FAOSTAT-a

Prilikom izračunavanja i analize mjera tačnosti tri modela trenda uočavamo da model kvadratnog trenda ima najmanje vrijednosti, te ga uzimamo kao adekvatnog za predviđanje površina krompira u naredne tri godine. (tabela 2)

Tabela 2. *Mjere tačnosti*

Model trenda	MAPE	MAD	MSD
Linearni	7	2966	14612487
Eksponencijalni	7	3023	14971216
Kvadratni	6	2485	11716193

Izvor: Obračun autora

Na narednom grafikonu 1 predstavljeno je kretanje površina krompira, gdje su plavom bojom date stvarne vrijednosti kretanja površina krompira, crvenom bojom zadate vrijednosti a zelenom predviđene vrijednosti ovog proizvodnog pokazatelja krompira u BiH.

Grafik 1. *Kretanje površina pod krompirom*

Izvor: Autor

Predviđene vrijednosti površine krompira u narednom trogodišnjem periodu biće u opadanju. U 2021. godini može se očekivati da će pod krompirom u BiH biti 28.000 hektara što je za nekih 12.130 ha manje od ostvarenog prosjeka i 6.100 ha manje od ostvarenog minimuma u analiziranom periodu. (tabela 3)

Tabela 3. *Predviđanje površina pod krompirom*

Godine	Predviđene vrijednosti površine krompira (ha)
2019.	30.644,3
2020.	29.358,1
2021.	28.009,0

Izvor: Obračun autora

Kada je izbor adekvatnog modela za predviđanje proizvodnje krompira u pitanju, ponovo uočavamo da je model kvadratnog trenda najpogodniji, odnosno da ima najmanje dobijene vrijednosti mjera tačnosti (MAPE, MAD, MSD). (Tabela 4)

Tabela 4. *Mjere tačnosti*

Model trenda	MAPE	MAD	MSD
Linearni	13	44260	2712222316
Ekspencijalni	13	44607	2736077622
Kvadratni	11	37554	2202595073

Izvor: Obračun autora

Kretanje i vizuelizacija proizvodnje krompira u analiziranom i predikcionom periodu data je na sledećem grafiku 2.

Grafik 2. Kretanje proizvodnje krompira

Izvor: Autor

Kao i kod površina, tako i kod proizvodnje krompira dolazi do smanjenja u predikcionom periodu. Naime, u zadnjoj godini perioda predviđanja (2021) može se očekivati proizvodnja od 311.688 tona što je ipak manje od ostvarenog prosjeka proizvodnje krompira u posmatranom periodu (1992–2018). Jedan od razloga smanjenja proizvodnje krompira je u smanjenju površina ovog povrtarskog usjeva u istom periodu. (tabela 5)

Tabela 5. Predviđanje proizvodnje krompira

Godine	Predviđene vrijednosti proizvodnje krompira (t)
2019	333.915,0
2020	323.218,0
2021	311.688,0

Izvor: Obračun autora

Mjere tačnosti korišćene za izbor modela predviđanja prinosa krompira pokazuju da je kao i kod prethodna dva proizvodna parametra krompira model kvadratnog trenda najpogodniji. (tabela 6)

Tabela 6. Mjere tačnosti

Model trenda	MAPE	MAD	MSD
Linearni	9,92931	0,87729	1,15223
Eksponencijalni	10,0866	0,89890	1,17210
Kvadratni	9,92380	0,87211	1,13047

Izvor: Obračun autora

Na grafikonu 3 dato je kretanje prinosa u posmatranom periodu, kao i kretanje prinosa u predikcionom periodu.

Grafik 3. Kretanje prinosa krompira

Izvor: Autor

Za razliku od prethodna dva pokazatelja krompira, možemo očekivati da će prinos krompira pokazati veoma blagu tendenciju rasta i da će biti veći u svim godinama predviđanja od ostvarenog prinosa u periodu analize.(tabela 7)

Tabela 7. Predviđanje prinosa krompira

Godine	Predviđene vrijednosti prinosa krompira (t/ha)
2019	10,66
2020	10,70
2021	10,74

Izvor: Obračun autora

ZAKLJUČAK

Krompir zauzima značajno mjesto u proizvodnji hrane u Bosni i Hercegovini. Prosječna površina u periodu (1992-2018) pod ovom povrstarskom vrstom bila je 40.145 ha. Prosječna proizvodnja krompira iznosila je 370.825 tona, a ostvareni prosječan prinos bio je na nivou od 9,3 t/ha.

Površine pod krompirom postepeno će se smanjivati u narednom trogodišnjem periodu (2019-2021), te će u zadnjoj godini predikcionog perioda iznositi 28.000 hektara, što je ispod ostvarenog prosjeka u periodu analize.

Proizvodnja krompira u BiH, kao i površina krompira, pokazaće tendenciju pada a u 2021. godini može se očekivati da će biti na nivou od 311.688 tona, što je kao i kod površine manje od zabilježenog prosjeka u periodu posmatranja.

Prinos krompira je jedini proizvodni pokazatelj krompira koji će rasti, istina veoma blago, u periodu trogodišnjeg predviđanja. Očekuje se da će u zadnjoj godini predikcije (2021) prinos krompira u BiH iznositi 10,7 t/ha.

Predviđanje proizvodnih pokazatelja krompira u ovom radu treba da posluži pri donošenju pravovremenih i racionalnih odluka koje se tiču budućeg razvoja ove poljoprivredne grane u BiH.

LITERATURA

1. FAO (2020). *Global potatoes production*, portal of the FAO, Rome, Italy, retrieved at: <http://www.fao.org/faostat/en/#data/QC>, 15 Jun 2020.

2. Goodwin, P., Lawton, R. (1999). On the asymmetry of the symmetric MAPE. *International Journal of Forecasting*, 15(4), pp. 405-408.
3. Hossain, M. M., Abdulla, F. (2016). Forecasting Potato Production in Bangladesh by ARIMA Model, *Journal of Advanced Statistics*, Vol. 1, No. 4
4. Hossain, M.M., Abdulla, F. (2015). On the production behaviors and forecasting the tomatoes production in Bangladesh, *Journal of Agricultural Economics and Development*, 4(5), pp. 66-74.
5. Ivanišević D. (2015). Predviđanje proizvodno-ekonomskih parametara u povrtarstvu u Srbiji, Doktorska disertacija, Poljoprivredni fakultet, Univerzitet Novi Sad.
6. Karim, R., Awala, A., Akhter, M. (2010). Forecasting of Wheat production in Bangladesh, *Bangladesh J. Agril. Res.* 35(1): 17-28.
7. Lazić, D. (2014). Analiza i predviđanje proizvodnje povrća u zemljama EU-master rad, Poljoprivredni fakultet, Novi Sad
8. Makridakis, S., Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting*, 16(4), pp. 451-476
9. Maksimović, P., Bročić, Z. (2005). Proizvodnja krompira, Agronomski fakultet, Čačak, Srbija
10. Mutavdžić Beba, Novković, N., Ivanišević, D. (2011). Tendencije razvoja povrtarstva u Srbiji, Zbornik radova XVI međunarodno-stručnog savetovanja agronoma Republike Srpske, Poljoprivredni fakultet Banja Luka, Trebinje 22-25.3, str. 113.
11. Mutavdžić Beba, Novković, N., Ivanišević, D. (2011a). Tendencije razvoja povrtarstva u Srbiji, Agroznanje, Univerzitet u Banja Luci, Poljoprivredni fakultet, Vol. 12, br. 1, str. 23-31.
12. Mutavdžić, Beba, Drinić, Lj., Novković, N., Ostojić, A., Rokvić, G. (2013). Prediction of vegetable production in Republic of Srpska, Fourth International Scientific Symposium „Agrosym 2013“- Book of Proceedings, and Book of Abstracts, University of East Sarajevo, Faculty of Agriculture, BiH. University of Belgrade, faculty of Agriculture, Serbia, Jahorina, str. 1276-1282; 281.
13. Mutavdžić Beba (2010). Analiza i predviđanje proizvodno-ekonomskih parametara u poljoprivredi Vojvodine-doktorska disertacija, Beogradski univerzitet, Poljoprivredni fakultet, Zemun

14. Novković, N., Beba Mutavdžić, Ivanišević, D. (2012). Development of Vegetable Production in Vojvodina Region, Book of Abstracts, I International Symposium and XVII Scientific Conference of Republic of Srpska, Faculty of Agriculture, University of Banja Luka and Biotechnical Faculty, University of Ljubljana, str. 54.
15. Novković, N., Mutavdžić Beba, Šomodić, Š. (2009). Modeli predviđanja u povrtarstvu, CD tematski zbornik naučnog skupa i Zbornik apstrakata: Poslovno okruženje u Srbiji i svetska ekonomska kriza, selekcija III, Visoka poslovna škola, Novi Sad, 521 (497.113), str. 85
16. Novković, N., Mutavdžić, B., Šomodić, Š. (2010). Modeli za predviđanje u povrtarstvu, Visoka poslovna škola strukovnih studija, Škola biznisa (3), str. 41-49.
17. Poštić, D. (2013). Uticaj porekla sadnog materijala i veličine semenske krtole na morfološke i produktivne osobine krompira, doktorska disertacija, Poljoprivredni fakultet, Univerzitet Novi Sad, Srbija, str. 1.
18. Puškarić, A. (2007). Stanje i tendencije tržišta krompira u Republici Srbiji, Monografija, Institut za ekonomiku poljoprivrede Beograd, str. 7.
19. Vlahović, B. (2003). Tržište poljoprivredno-prehrambenih proizvoda-specijalni deo-knjiga II, Poljoprivredni fakultet, Novi Sad, str. 8.

FORECASTING RESULTS, FARMING AREA AND YIELD OF POTATO PRODUCTION IN BOSNIA AND HERZEGOVINA

Miroslav Nedeljković

Jovana Vujić

Abstract: *The aim of the authors was to create an adequate trend model that would be able to forecast the results of potato production in Bosnia and Herzegovina for a three-year period (2019-2021) by using quantitative research method and trend analysis. Data collected*

during twenty-seven years (1992-2018) were used for forecasting, and the research results have indicated that the farming area and production of potato will decrease, while yield will be the only parameter of potato production that will show the tendency of growth in the observed three-year period. The obtained research results can be used for making strategic decisions related to the development of this branch of agricultural production.

Key words: forecasting, production, area, yield, trend, potato, BiH