

ISSN 1330-7142
UDK = 311.17: 63

STATISTIČKA KONTROLA PROCESA I PROIZVODA U POLJOPRIVREDI

D. Horvat, Andrijana Eđed, Đ. Banaj

Stručni članak
Professional paper

SAŽETAK

Osnovni koncept statističke kontrole procesa temelji se na uspoređivanju podataka dobivenih iz procesa s izračunatim kontrolnim granicama te na osnovi toga donošenje zaključaka o samome procesu. Statistička kontrola procesa i kvalitete poljoprivrednih proizvoda koristi se da bi se osigurala kakvoća proizvoda koji će zadovoljiti zahtjeve kupaca, u pogledu kvalitete i u cijeni koštanja istih. U skladu sa standardima ISO 9000, utvrđene su norme kvalitete proizvoda i procesa. Mnoge institucije u Hrvatskoj prihvatile su zadane norme i rade u skladu s njima. Da bi se što više približili zadanim normama i smanjili troškove proizvodnje, pravilna primjena statističke kontrole kvalitete i kontrolnih karata može biti od velike koristi. Za ilustraciju navedenoga, ispitana je kvaliteta rada mlaznice prskalice zahvata osamnaest metara.

Ključne riječi: statistička kontrola procesa, statistička kontrola kvalitete, kontrolna karta

UVOD

Zahtjev za kvalitetom star je gotovo kao ljudska civilizacija i javlja se već u prvim oblicima "trgovine", odnosno materijalne razmjene. Poznato je da je prije više od četiri tisuće godina u doba egipatskih, feničanskih, grčkih, rimskih i arapskih trgovaca bilo doba procvata obrta i trgovine. Razumljivo je da su pri takvim trgovinama kupci često bili prevareni. Već oko 2100. godine prije naše ere donesen je prvi poznati Zakon o zaštiti kupaca i malih poduzetnika od prijevara.

Tijekom povijesti ljudskoga roda naponi su se sustavno ulagali u potvrđivanje kvalitete i to ne samo proizvoda i dobara, već i proizvođača i isporučitelja. Možemo slobodno reći da kontrola kvalitete (*quality control - QC*) ima dugu povijest. Međutim, statistička kontrola kvalitete (*statistical quality control - SQC*) relativno je nova metoda. Počela se uspješno primjenjivati dvadesetih godina prošloga stoljeća, kao rezultat prihvaćanje teorije uzoraka. Koncept kontrole kvalitete u proizvodnji prvi je uveo dr. Walter A. Shewart, koji je 1924. godine izumio kontrolne karte. Za svoj rad nikada nije dobio zaslužen priznanje, ali su na osnovu njegovih saznanja Deming, Juran, Ishikawa i mnogi drugi tijekom dvadesetoga stoljeća, razvijali i konstantno unaprjeđivali koncept statističke kontrole kvalitete. U međunarodnoj normi (ISO 9000) naziv kvaliteta - kakvoća (potječe od latinske riječi «*qualitas*», što znači kakvoća, svojstvo, vrsnoća, značaj odlika) - određen je kao *ukupnost svojstava entiteta, koja ga čine sposobnim da zadovolji izražene ili pretpostavljene potrebe*. Kvalitetu još možemo definirati kao:

- Sposobnost za uporabu (*fitness for use*)
- Sposobnost za primjenu (*fitness for purpose*)
- Korisnikovo zadovoljstvo (*customer satisfaction*)
- Sukladnost sa zahtjevima (*conformance to the requirements*)

Riječ «kontrola» odnosi se na proces koji se primjenjuje radi zadovoljavanja normi. Sastoji se od promatranja stvarnoga ispunjavanja funkcije, usporedbe ispunjavanja te funkcije s nekom normom i djelovanja, ako se promatrano ispunjavanje funkcije značajno razlikuje od norme.

Proces kontrole nalik je povratnoj vezi. Kontrola obuhvaća opći sljed koraka, kako je navedeno (Juran, 1999.):

Dr.sc. Dražen Horvat, izv.prof., Andrijana Eđed, dipl.inž. i dr.sc. Đuro Banaj, red.prof. – Poljoprivredni fakultet u Osijeku, Sveučilište Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, 31000 Osijek

1. izbor predmeta kontrole, odnosno izabiranje onoga što namjeravamo kontrolirati,
2. izabiranje jedinice mjere,
3. postavljanje cilja za predmet kontrole,
4. stvaranje senzora koji može mjeriti predmet kontrole pomoću mjernih jedinica,
5. mjerenje stvarnoga ispunjavanja funkcije,
6. tumačenje razlike između stvarnoga ispunjavanja funkcije i cilja,
7. djelovanje (ako je potrebno) po razlici.

Ovdje navedeni sljed koraka je općenit, tj. primjenjuje se na kontrolu troškova, kontrolu zaliha, kontrolu kvalitete itd. Kontrola kvalitete najveću primjenu ima u industriji, ali se može primjenjivati kod svih procesa koji se odvijaju pod manje ili više istim uvjetima.

Težnja za postizanjem i održavanjem željenoga stupnja kvalitete (koji zadovoljava i proizvođača i potrošača) sve je veći. Propisani su zakoni i norme koje svaki entitet (ono što može biti pojedinačno opisano ili razmatrano, npr.: radnja, proces, proizvod, organizacija, sustav, osoba ili svaka njihova kombinacija) mora zadovoljiti. Danas su u Republici Hrvatskoj prihvaćeni ISO (International Organization for Standardization) standardi koji se provode kroz niz sustava i normi, a neke od njih su:

- HACCP sustav upravljanja sigurnošću u prehrambenoj industriji
- ISO 13488; ISO 9000 u medicini
- ISO TS 16949; ISO 9000 u automobilskoj industriji
- HRN EN ISO/IEC 17025; ISO 9000 za laboratorije
- ISO 9001/2000 sustav upravljanja kvalitetom
- HRN EN ISO 14001 sustav upravljanja okolišem.

Proces predstavlja kombinaciju strojeva, alata, metoda, materijala i ljudi koji ostvaruju rezultate u obliku roba, programa ili usluga. Statistička kontrola procesa (*statistical process control - SPC*) definirana je kao primjena statističkih metoda za mjerenje i analizu varijacija u bilo kojemu procesu.

STATISTIČKA KONTROLA KVALITETE

Statistička kontrola kvalitete je skup metoda i postupaka za prikupljanje, obradu, analizu, tumačenje i prikaz podataka. Koristi se u svrhu osiguranja kvalitete proizvoda i procesa. Pravilnom primjenom SQC moguće je smanjiti troškove proizvodnje. Mehanizam statističke kontrole poljoprivrednih proizvoda zasniva se na definiranju granica tolerantnosti na ispravnost proizvoda ili varijabilnost od neke standardne ili propisane mjere. Ako se kvaliteta proizvoda nalazi u tim okvirima, smatra se da je pod kontrolom ili kvalitativno zadovoljavajuća.

Razlozi za primjenu statističke kontrole kvalitete su sljedeći:

- utvrđivanje sposobnosti procesa za proizvodnju proizvoda koji zadovoljava zahtjeve,
- praćenje procesa kako bi se otkrile promjene zbog kojih proces izmiče kontroli,
- poduzimanje mjera za korekciju procesa i njegovo održavanje pod kontrolom.

Statistička analiza može samo upozoravati na nastale promjene, a moguće uzroke treba naknadno utvrditi. Statistička analiza ne mjeri uzroke odstupanja, niti ukazuje što treba poduzeti za uklanjanje odstupanja.

Zahvaljujući mnoštvu kontrolnih tehnika mnogo je načina za provođenje statističke kontrole kvalitete procesa i poljoprivrednih proizvoda. Osnovni alati za praćenje i ispitivanje kontrole kvalitete, uključuju:

- histogram,
- kontrolne tablice,
- Pareto karte,
- dijagram uzroka i posljedica (Ishikawa dijagram ili “riblja kost”)
- dijagram rasprostiranja (scatter diagram),
- kontrolne karte .

KONTROLNE KARTE

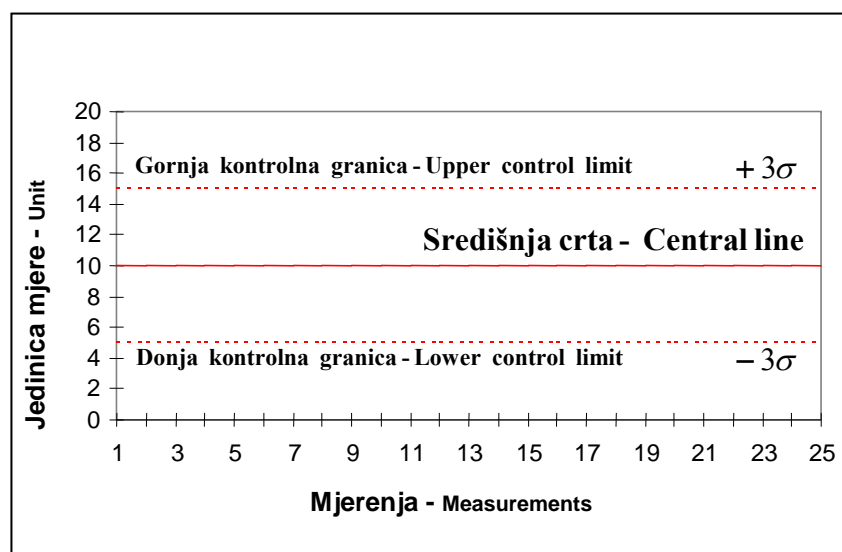
Kontrolne su karte (*control chart*) osnovni instrument pomoću kojega se provodi statistička kontrola proizvoda ili proizvodnoga procesa. Osnovna uloga kontrolnih karata je u otkrivanju i vizualizaciji poremećaja kvalitete proizvoda. Kontrolna karta sastoji se od tri osnovne kontrolne granice :

- gornja kontrolna granica (*upper control limit - UCL*),
- središnja crta (*central line - CL*),
- donja kontrolna granica (*lower control limit - LCL*).

Kontrolna karta kreira se na osnovi aritmetičkih sredina određenoga broja uzoraka k , od kojih se svaki sastoji od po nekoliko jedinica. Centralna linija utvrđuje se na osnovi aritmetičke sredine aritmetičkih sredina uzoraka, odnosno:

$$\bar{\bar{X}} = \frac{\sum \bar{X}_i}{k}$$

Kontrolne granice izračunavaju se pomoću zakona vjerojatnosti, na osnovi raspodjele uzoraka. Iste se određuju iz odnosa $\frac{\bar{X} \pm 3\sigma}{\sqrt{n}}$, odnosno nalaze se u okviru $\bar{X} \pm 3\sigma_x$.




Grafikon 1. Osnovna \bar{X} kontrolna karta za prosjeke
Chart 1. The basic \bar{X} control chart

Varijacije unutar procesa mogu nastati kao posljedica dvije vrste uzroka:

1. opći ili sustavni (*common causes*), koji su svojstveni procesu (npr. genotipske varijacije),
2. specifični ili posebni (*special causes*), koji uzrokuju pretjeranu varijaciju.

Kontrolne se karte koriste za razlikovanje tih dviju vrsta varijacija u procesu, na osnovu analize podataka iz prošlosti i budućnosti.

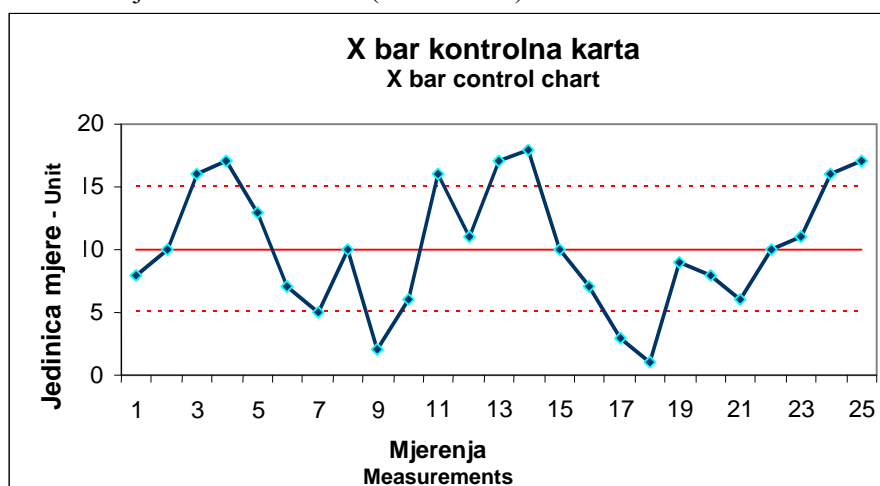
Predviđanja statističara pretpostavljaju stabilnu populaciju. To je ona populacija koja se može ponoviti, to jest ona populacija koje je u stanju «statističke kontrole». U takvoj populaciji prisutni su samo sustavni uzroci varijacije, a oni uvjetuju stabilan proces koji vodi do najmanje varijacije. Kontrolna karta za takve procese ima sve točke s podacima unutar statističkih kontrolnih granica.



Grafikon 2. Proces je «u stanju statističke kontrole»

Chart 2. Process is statistically “in control”

Kontrolne granice izračunavaju se pomoću zakona vjerojatnosti, na takav način da se za veoma nevjerovatne uzroke varijacije pretpostavlja da nisu nastale zbog slučajnih uzroka, nego da su nastale kao posljedica posebnih uzroka. Kad varijacija prelazi statističke kontrolne granice, to je znak da su posebni uzroci ušli u proces i da proces treba ispitati kako bi se utvrdili uzroci pretjerane varijacije. Za takav proces kažemo da je «izvan kontrole» (Grafikon 3.).



Grafikon 3. Proces je «izvan statističke kontrole»

Chart 3. Process is statistically “out of control”

Uzevši u obzir vrstu podataka, na osnovi kojih pravimo kontrolnu kartu, razlikujemo dva osnovna tipa kontrolnih karata (www.itl.nist.gov):

1. Kontrolne karte za opisna (atributivna) svojstva:
 - p karta (p chart) – postotak nesukladnosti (proportion)
 - c karta (c chart) – broj nesukladnosti (count)
 - u karta (u chart) – prosječan broj nesukladnosti po jedinici proizvodnje (*per unit*)
2. Kontrolne karte za mjerna (numerička) svojstva
 - \bar{X} karta (X bar chart)
 - R karta (R chart)

KONTROLNE KARTE ZA MJERNA (NUMERIČKA) SVOJSTVA

Za mjerna svojstva koriste se \bar{X} karta (*X bar chart*) i R karta (*R chart*). Te dvije vrste kontrolnih karata nazivaju se još i Shewartove kontrolne karte. Njihova konstrukcija temelji se na prosjecima i rasponima uzoraka. Potrebno je skupiti veći broj uzoraka (najmanje 50 – 100), koje treba podijeliti u podgrupe, iz kojih se izračunavaju prosjeci (\bar{X}) i rasponi (R). Tek tada se pristupa izračunavanju središnje crte i kontrolnih granica. Središnja crta može biti prosjek prošlih podataka ili željeni prosjek (tj. normizirana vrijednost). Kontrolne se granice obično postavljaju na tri standardna odstupanja ($\pm 3\sigma$) za prosjeke i raspone uzorka, ali se mogu odabrati i druge vrijednosti kontrolnih granica (npr. pomoćne kontrolne linije na $\pm 1\sigma$ i $\pm 2\sigma$). Osnovne formule za izračunavanje kontrolnih granica baziraju se na $\pm 3\sigma$ i koriste središnju crtu, koriste središnju crtu koja je jednaka prosjeku podataka koji se koriste za izračunavanje kontrolnih granica.

Kontrolne se granice vrlo lako izračunavaju pomoću statističkih programa (SPSS, Statistica, SAS i drugi), koji omogućavaju i izradu kontrolnih karata, a postoje i nadogradnje koje u Microsoft Excelu omogućavaju izradu kontrolnih karata. Također, postoje skraćene formule za izračunavanje kontrolnih granica \bar{X} i R karata. Postupak izrade R karata sastoji se od izračunavanja pojedinačnih raspona za svaki uzorak. Raspone čine razlike između najvećih i najmanjih izmjera u uzorku. Iz tako dobivenih raspona izračunava se prosječni raspon \bar{R} . Izrada \bar{X} karata temelji se na izračunavanju velikoga prosjeka ($\bar{\bar{X}}$), koji predstavlja prosjek prosjeka svih uzoraka. Naposljetku, izračunavaju se kontrolne granice \bar{X} i R karata, na osnovi kojih se izrađuju kontrolne karte.

Primjer izrade \bar{X} kontrolne karte

Za izradu \bar{X} kontrolne karte uzeli smo podatke o protoku tekućine (l/min) kroz mlaznice prskalice Rau Spridomat D2 radnoga zahvata osamnaest metara, s ukupno trideset i šest mlaznica ($k=36$), međurazmaka 50 cm. Mjeren je protok tekućine kroz svaku mlaznicu na svakih 20 cm, na dužini od jednoga metra ($n=5$).



Slika 1. Mjerenja su obavljena na prskalici Rau Spridomat D2 radnoga zahvata 18 metara
Figure 1. Measurements were performed on Rau Spridomat sprayer, working clutch 18 meters

Tablica 1. Rezultati mjerenja protoka ispitne tekućine (l/min)

Table 1. Results of nozzle flow measurement (l/min)

	0,2 m	0,4 m	0,6 m	0,8 m	1,0 m	Prosjek	Raspon
1.	0,4720	0,2390	0,2760	0,3960	0,4530	0,3672	0,2330
2.	0,3570	0,3620	0,2140	0,3210	0,3630	0,3234	0,1490
3.	0,2580	0,3400	0,3350	0,4160	0,3260	0,3350	0,1580
4.	0,2440	0,3840	0,2760	0,2590	0,3220	0,2970	0,1400
5.	0,2470	0,3450	0,3070	0,2670	0,3300	0,2992	0,0980
6.	0,3130	0,3320	0,3260	0,2530	0,3470	0,3142	0,0940
7.	0,2480	0,3060	0,2360	0,2980	0,3420	0,2860	0,1060

8.	0,3220	0,3210	0,2870	0,2120	0,2170	0,2718	0,1100
9.	0,1840	0,2680	0,2110	0,1990	0,2060	0,2136	0,0840
10.	0,3040	0,1810	0,2840	0,2640	0,1670	0,2400	0,1370
.
.
32.	0,3190	0,2930	0,2780	0,3330	0,3410	0,3128	0,0630
33.	0,3220	0,3450	0,3450	0,4020	0,3330	0,3494	0,0800
34.	0,3720	0,3840	0,3980	0,3990	0,4490	0,4004	0,0770
35.	0,2940	0,4190	0,4700	0,3930	0,4210	0,3994	0,1760
36.	0,3640	0,3830	0,3930	0,1630	0,0430	0,2692	0,3500
						0,3053	0,1270

Takozvani «veliki prosjek $\bar{\bar{X}}$ » i raspon \bar{R} izračunavaju se kako sljedi:

$$\bar{\bar{X}} = \frac{0,3672 + 0,3234 + 0,3350 + \dots + 0,2692}{36} = \frac{10,9902}{36} = 0,3053$$

$$\bar{R} = \frac{0,2330 + 0,1490 + 0,1580 + \dots + 0,3500}{36} = \frac{4,5720}{36} = 0,1270$$

Pri izračunavanju kontrolnih granica ograničenih na tri standardne devijacije ($\pm 3\sigma$) koriste se koeficijenti za izračunavanje kontrolnih granica (Tablica 2.).

Tablica 2. Koeficijenti potrebni za izračunavanje kontrolne linije

Table 2. The coefficients for calculating the control lines

N	A2 ¹	D4 ²	D3 ³
2	1,88	3,267	0,00
3	1,023	2,575	0,00
4	0,729	2,282	0,00
5	0,577	2,115	0,00
6	0,483	2,004	0,00
7	0,419	1,924	0,076
8	0,373	1,864	0,136
9	0,337	1,816	0,184
10	0,308	1,777	0,223

Izvor-Source: Juran, 1999.

¹A2 su koeficijenti za izračunavanje kontrolnih granica za \bar{X} kartu

²D4 su koeficijenti za izračunavanje UCL za R kartu

³D3 su koeficijenti za izračunavanje LCL za R kartu

Izračunavanje kontrolnih granica za \bar{X} kontrolnu kartu:

Središnja crta (CL) = $\bar{\bar{X}}$

Gornja kontrolna granica (UCL) = $\bar{\bar{X}} + A2 * \bar{R}$

Donja kontrolna granica (LCL) = $\bar{\bar{X}} - A2 * \bar{R}$


U našem primjeru središnja crta i kontrolne granice računaju se na sljedeći način:

Središnja crta (CL) je jednaka $\bar{\bar{X}}$ i iznosi 0,3053, a prosječni raspon \bar{R} iznosi 0,1270 za uzorke veličine n=5.

$$UCL = 0,3053 + 0,577 * 0,1270 = 0,378579$$

$$LCL = 0,3053 - 0,577 * 0,1270 = 0,232021$$

Na osnovi izračunatoga napravljena je kontrolna karta.



Grafikon 4. Standardna kontrolna karta u provjeri protoka ispitne tekućine
Chart 4. Standard control chart in a testing of nozzle flow

Iz kontrolne karte vidljivo je da protok tekućine kroz mlaznice nije ujednačen te da kod pojedinih mlaznica dolazi do otklona u odnosu na kontrolne granice. Takvo stanje procesa označava se terminom «izvan statističke kontrole» i ukazuje da pojedine mlaznice, na kojima dolazi do otklona, treba podesiti ili zamijeniti. Tako, na primjer, mlaznice 9., 27. i 28. imaju manju protočnost, a 34. i 35. mlaznica veću protočnost, odnosno njihove se vrijednosti nalaze izvan kontrolnih granica.



Slika 2. Digitalni uređaj za kontrolu ispravnosti rada prskalice
Figure 2. Device for accuracy control of sprayer running

ANALIZA KONTROLNIH KARATA

Osim precizne izrade kontrolnih karata, od velike je važnosti i njihovo pravilno tumačenje. Najjednostavnije je tumačiti kontrolne karte kod kojih se proces nalazi «izvan statističke kontrole», odnosno onaj proces kod kojega se vrijednosti pojedinih mjerenja nalaze izvan kontrolnih granica. To znači da je u procesu prisutan neki od posebnih uzroka varijacije i da treba obaviti prilagodbu.

Međutim, smještaj svih točaka unutar kontrolnih granica, odnosno dobivanje kontrolne karte na kojoj je proces «unutar statističke kontrole», ne mora značiti da je takav proces prihvatljiv od strane statističara.

Kod tumačenja kontrolnih karata koristi se niz termina za opisivanje pojedinoga stanja na kontrolnoj karti, koja prikazuje proces «unutar kontrole» (Juran, 1999.):

RUN (tok ili tendencija) – javlja se kada se sedam točaka u nizu nalaze s gornje ili donje strane središnje crte, ali unutar kontrolnih granica. Takav izgled kontrolne karte kazuje nam da u procesu postoje nepravilnosti koje treba korigirati.

TREND (trend, nagib) – ukoliko na kontrolnoj karti postoji sljed točaka čije vrijednosti kontinuirano opadaju ili rastu, ukazuje nam da proces izmiče kontroli i obično je potrebno ugoditi stroj.

PERIODICITY (periodičnost) – evidentna je kada se unutar procesa u istim razmacima javljaju promjene cikličkoga tipa.

HUGGING (držanje) – nepravilnost koja se javlja kada su izmjerene vrijednosti smještene vrlo blizu središnje crte ili kontrolnih granica.

Analiziranju svake pojedine kontrolne karte treba pristupiti vrlo ozbiljno i studiozno. Na osnovi rezultata kontrolne karte, moguće je unaprijediti proizvodni proces, otkloniti neželjene uzroke varijacije, smanjiti troškove proizvodnje, a samim time i povećati dobit. Kontrolna karta, kao sredstvo u kombinaciji sa znanjem onih koji vode proces, zamjenjuje intuitivno odlučivanje o procesu, donošenjem odluka na znanstvenoj osnovi.

ZAKLJUČAK

Poboljšanje kvalitete proizvoda moguće je postići unaprjeđenjem procesa proizvodnje koji može biti učinkovitiji pomoću statističke kontrole kvalitete. Ista rabi statističku analizu u cilju praćenja, kontrole i neprekidnoga poboljšavanja procesa. Niska proizvodnost, proizvodi koji ne zadovoljavaju potrebe tržišta, oštećeni proizvodi i drugo rezultat su varijacija u procesu. Procjenjuje se da je oko 94% varijacija u procesu rezultat običnih varijacija koje su svojstveni procesu (npr. genotipske varijacije), a preostalih 6% varijacija posljedica su posebnih uzroka varijacije. Statistička kontrola procesa i kvalitete poljoprivrednih proizvoda unaprjeđuje proces tako što smanjuje uzroke varijacije u njima. Kao osnovni alat statističke kontrole kvalitete koriste se kontrolne karte. One služe za usporedbu podataka o procesnom ispunjavanju funkcije s izračunatim statističkim kontrolnim granicama ucrtanim kao granične crte na karti. Postoji veliki broj kontrolnih karata za mjerljiva i opisna svojstva, koje nalaze sve više mogućnosti za primjenu u svim područjima. Približavanjem Republike Hrvatske Europskoj uniji i prihvaćanjem međunarodnih normi ISO 9000 u svakoj proizvodnoj djelatnosti, postavljeni su kriteriji, odnosno norme kvalitete, koje svaki proizvod mora ispunjavati da bi mogao izići na tržište. Statistička kontrola kvalitete, pomoću svojih alata, a osobito kontrolnih karata, uvelike može pridonijeti postizanju tih zadanih normi. Ispitivanjem mlaznica na prskalici Rau Spridomat D2 i njihovom statističkom analizom ukazano je na neujednačeni protok tekućine kroz mlaznice, na što ukazuju izvjesni otkloni u odnosu na kontrolne granice. Sve navedeno tehnolozi bi trebali uvažiti, a po potrebi i korigirati protoku, glede poboljšanja kvalitete rada prskalice u narednim radnim procesima.

LITERATURA

1. Juran, J.M., Gryna, M.F. (1999.): Planiranje i analiza kvalitete. MATE, Zagreb: p. 664.
2. Crosby, P. B. (1996): Quality Is Still Free: Making Quality Certain In Uncertain Times. McGraw-Hill. New York: p. 205
3. Deming, W. E. (1986): Out of the crisis. MIT Center for Advanced Engineering Study. MIT Press, Cambridge.
4. Enginering Statistics Handbook: „How did Statistical Quality Control Begin?“. URL: <http://www.itl.nist.gov/div898/handbook/pmc/section1/pmc11.htm> (11.05.2006.)
5. Hadživuković, S. (1989.): Statistika. Privredni pregled – Beograd: p. 271.
6. Ishikawa, K. (1994): What He thought and Achieved, A Basis for Further Research. Quality Management Journal: p. 86- 91
7. StatSoft, Inc. (2004). STATISTICA (data analysis software system), version 7.
8. Woodall, W. H, (2000) : Controversis and Contradictions in Statistical Process Control. Journal of Quality technology Session, October 12-13.
9. Zimmerman, S.M., Icenogle M.L. (2003): Statistical quality control using Excel (Second Edition). ASQ Quality Press Milwaukee.

STATISTICAL CONTROL OF PROCESSES AND PRODUCTS IN AGRICULTURE

SUMMARY

Fundamental concept of statistical process control is based on decision-making about the process on the basis of comparison of data collected from process with calculated control limits. Statistical process and quality control of agricultural products is used to provide agricultural products that will satisfy customer requirements in a view of quality pretension as well as costumer requirements in a cost price. In accordance with ISO 9000, quality standards for process and products are defined. There are many institutions in Croatia that work in accordance with these standards. Implementation of statistical process control and usage of a control charts can greatly help in convergence to the standards and in decreasing of production costs. To illustrate the above mentioned we tested a work quality of a nozzle at the eighteen meter clutch sprayer.

Key-words: statistical process control, statistical quality control, control chart

(Primljeno 04. svibnja 2006.; prihvaćeno 09. lipnja 2006. - Received on 4 May 2006; accepted on 9 June 2006)