

STATISTIČKA ANALIZA SPOSOBNOSTI PROCESA PROIZVODNJE STRETCH FOLIJE

STATISTICAL ANALYSIS OF STRETCH FILM PRODUCTION PROCESS CAPABILITIES

Goran Kovačić, Živko Kondić

Stručni članak

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. Ovaj postupak se prepoznaće kao suvremena metoda za analizu sposobnosti procesa preko različitih indeksa sposobnosti. U radu se opisuje primjena ove metoda pri praćenju i analizu sposobnosti procesa proizvodnje stretch folije.

Ključne riječi: Sposobnost procesa, indeksi sposobnosti procesa, kvaliteta

Professional paper

Abstract: The basic concept of statistical process control is based on the comparison of data collected from the process with calculated control limits and conclusions about the process based on the above. This process is recognized as a modern method for the analysis of process capabilities over different capability indexes. This paper describes the application of this method in monitoring and analysis of stretch film production process capabilities.

Key words: process capabilities, process capability indexes, quality

1. UVOD

Sposobnost procesa se procjenjuje računanjem tzv. indeksa sposobnosti procesa, ali i pomoću drugih pokazatelja koji nisu toliko važni za primjenu u industriji. Proces je sposoban ako je raspon zahtjeva veći ili jednak od raspona procesa. To je ujedno i temeljni uvjet sposobnosti procesa. Raspon zahtjeva, odnosno tolerancijsko područje T je područje između gornje (USL) i donje granice zahtjeva (LSL), odnosno

$$T = USL - LSL \quad (1)$$

Raspon procesa podrazumijeva područje unutar ± 3 standardna odstupanja (6σ) u odnosu na sredinu procesa (99,73 % površine ispod krivulje normalne raspodjele kojom se aproksimira proces). Temeljni uvjet sposobnosti procesa je:

$$T \geq 6\sigma \quad (2)$$

Ocjena sposobnosti procesa odgovara na pitanje treba li poboljšati proces. Ako je odgovor potvrđan, postavlja se pitanje za koliko ga treba poboljšati. Drugim riječima, ova se analiza svodi na razmatranje uzroka varijabilnosti procesa, budući da se u svakom procesu pojavljuje određeni stupanj varijabilnosti iz slučajnih ili posebnih uzroka. Ocjrenom sposobnosti procesa mjeri se učinkovitost i efikasnost procesa u slučaju nepostojanja posebnih uzroka varijacija, dakle u slučaju kada je proces u stanju statističke kontrole. Kad je proces pod

kontrolom bit će manja vjerojatnost da promatrani parametri procesa izađu izvan okvira kontrolnih granica. To će biti tako zbog toga jer se na proces može djelovati već u trenutku kada se pojave naznake da bi mogao izaći izvan kontrole, odnosno izvan specificiranih kontrolnih granica.

Također treba osigurati ne samo da je proces pod kontrolom, već i da je ispravno centriran u odnosu na definiranu i praćenu karakteristiku proizvoda ili nekog njegovog parametra.

Prije analiziranja sposobnosti procesa treba proces dovesti u stanje statističke kontrole i osigurati da je normalno distribuiran. Prema Breyfogleu [44], postoje tri statistička instrumenta za utvrđivanje je li proces pod kontrolom i jesu li njegovi izlazi normalno distribuirani, a to su:

- kontrolne karte
- histogrami
- matematička analiza distribucije

Prije ocjene sposobnosti procesa potrebno je izabrati kritični parametar ili promjenjivu veličinu koja će se kontrolirati. To je veličina koja se mora uklopiti u zadane tolerancije, npr. dimenzija neke pozicije ili bilo koja druga veličina. U složenijim slučajevima ocjene sposobnosti procesa, kritični parametri mogu biti rezultat nekoliko procesa. U takvim slučajevima ponekad je neophodno analizirati sposobnost svakog od tih procesa. Analize početnih procesa se najčešće pokazuju korisnije od analiza kasnijih procesa.

Kad se odabere kritični parametar, može se pristupiti prikupljanju rezultata mjerjenja. Kritični parametar treba biti mјeren što preciznijim mjerilom s klasom točnosti većom od veličine tolerancije. U suprotnom, proces mjerjenja će biti uzrok pojave varijacija na konkretnom parametru. Najbolje je prikupljati što više podataka tijekom dužeg vremenskog perioda. Tako se s većom pouzdanošću dobiva ocjena sposobnosti procesa jer se zasniva na velikom uzorku.

2. POKAZATELJI SPOSOBNOSTI PROCESA

Sposobnost procesa se procjenjuje računanjem tzv. indeksa sposobnosti procesa. Za taj izračun uvede se određene pretpostavke:

- razdioba podataka se aproksimira normalnom razdiobom,
- proces koji se analizira je stabilan i bez značajnih uzroka varijacija (proces je pod kontrolom),
- pouzdana procjena sposobnosti procesa može se donijeti samo temeljem praćenja procesa primjenom odgovarajuće kontrolne karte i nakon dovođenja procesa u stanje statističke kontrole (stanje „pod kontrolom“)

Kod uvođenja ovih pretpostavki važno je naglasiti da ako proces nije „pod kontrolom“ računanje indeksa sposobnosti je puka formalnost i zavaravanje. Pored toga važno je uočiti da otklanjanjem značajnih uzroka varijacija u procesu i dovođenjem sredine procesa u okoliš ciljane vrijednosti ima smisla procjenjivati njegovu sposobnost.

Indeksi sposobnosti procesa su koristan alat kada se statistički analiziraju podaci dobiveni mjerjenjem. Za njihovo izračunavanje potrebno je imati toleranciju ili dopuštene granice odstupanja. Indeks sposobnosti procesa „uzima“ informacije koje postoje u histogramu i svodi ih na samo jedan broj koji izražava jedan aspekt sposobnosti procesa. Indeksi sposobnosti procesa su pojedinačni brojevi, pa je to i prednost i nedostatak. Prednost se sastoji u tome što je najlakše uspoređivati jedan broj, a nedostatak što je jedan broj donekle ograničenog dometa.

Uvažavajući vrijeme odvijanja procesa, procjenjivanje sposobnosti (pripadajući indeksi) može pripadati jednoj od sljedeće tri kategorije:

1. Sposobnost procesa u dužem vremenskom razdoblju (Long-Term Process Capability)
2. Preliminarna sposobnost procesa (Preliminary Process Capability)
3. Sposobnost u kratkom vremenskom razdoblju (Short-Term Capability)

2.1. Sposobnosti procesa u dužem vremenskom razdoblju

Indeksi sposobnosti procesa računaju se nakon odvijanja procesa tijekom razložno dugog vremenskog razdoblja u kojem su se mogli pojaviti sve moguće varijacije procesa. Preporuka je 20 proizvodnih dana (tvrtka Ford). Indeksi su sljedeći:

- Potencijalna sposobnost C_p
- Omjer sposobnosti C_r
- Donja i gornja potencijalna sposobnost C_{pL} i C_{pU}
- Faktor korekcije necentriranosti k
- Demonstrirana izvrsnost - C_{pk}

2.1.1 Potencijalna sposobnost C_p

Ovaj se indeks računa kao odnos tolerancije prema 6σ :

$$C_p = \frac{T}{6\hat{\sigma}} = \frac{USL - LSL}{6\hat{\sigma}} \quad (3)$$

Vrijednost C_p pokazuje koliko je puta širina tolerantnog polja veća od stvarne širine odgovarajuće raspodjele. Pri ovome korištenje 6σ intervala kao etalona podrazumijeva implicitno usvajanje pretpostavke o normalnoj raspodjeli konkretnog parametra.

Standardno odstupanje se procjenjuje analizom odgovarajuće kontrolne karte, odnosno iz izraza:

$$\hat{\sigma} = \frac{\bar{R}}{d_2} \quad (4)$$

(u slučaju primjene $\bar{x} - R$ kontrolne karte) ili

$$\hat{\sigma} = \frac{\bar{s}}{C_2} \quad (5)$$

(u slučaju primjene $\bar{x} - s$ kontrolne karte).

Ovako procijenjeno standardno odstupanje naziva se „standardno odstupanje iz uzorka“ ili „unutrašnje standardno odstupanje“ (within subgroups or internal standard deviation).

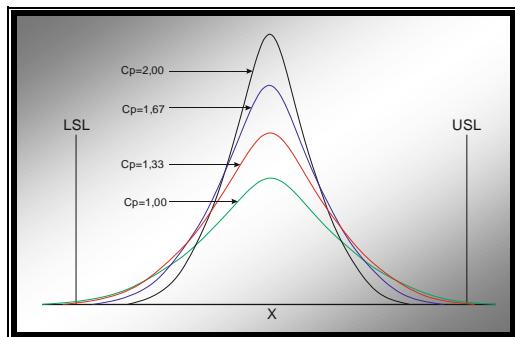
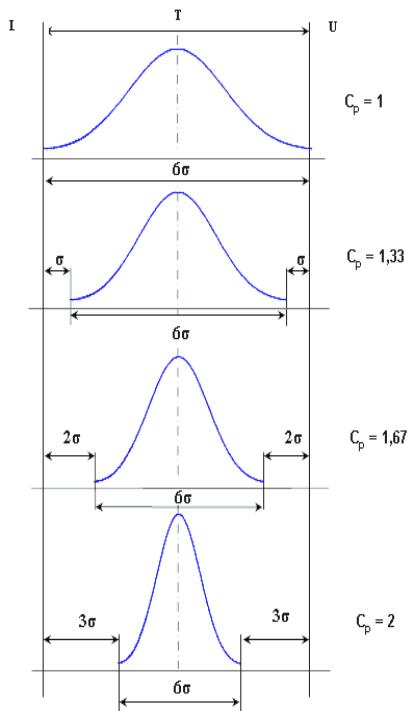
Vrijednost ovog indeksa neposredno pokazuje može li proces biti sposoban. Što je iznos indeksa veći, to je rasipanje procesa manje. Njegove vrijednosti se kreću oko nule do vrlo velikih pozitivnih brojeva. Što je vrijednost indeksa veća, to je manje rasipanje procesa.

Teorijski je proces sposoban ako je $C_p \geq 1$. Sve dok je srednja vrijednost rezultata mjerjenja jednaka centralnoj točki tolerancije, može se komentirati i povezati C_p i preciznost procesa (tabela 1). Nedostatak ovog indeksa je u tome što zanemaruje sredinu procesa, te se u slučaju loše centriranosti procesa može doći do pogrešnog zaključka.

Tabela 1. Vrijednost C_p i sposobnost procesa

C_p	Sposobnost procesa
> 1,33	Proces može biti sposoban
1,0 do 1,33	Moguća sposobnost je upitna, a proces treba i dalje nadzirati
< 1,00	Vrlo upitna sposobnost procesa

Na slikama 1 i 2 prikazana je povezanost širine raspodjele nekog parametra procesa s vrijednošću C_p . Na taj način, jedan od prvih i polaznih zadataka uvođenja faktora sposobnosti procesa (FSP) sastoji se u karakterizaciji procesa prema postotku škarta pomoću jednog jednostavnog broja. Različite tvrtke usvajaju za svoje procese različite kritične vrijednosti C_p . Mnogi japanski proizvođači orientiraju se na vrijednosti $C_p = 1,33$, što odgovara takvoj situaciji kada interval $\pm 3\sigma$ zauzima 75% od polja dopuštenog odstupanja. Ovu vrijednost za C_p koristi i tvrtka „Ford“ kao etalon, dok se u tvrtkama „Reno“ kao kritična vrijednost C_p koristi 1. Neke tvrtke ovu vrijednost podižu na 1,67, odnosno na $C_p \geq 2$.

**Slika 1.** Primjeri koeficijenta C_p **Slika 2.** Različite vrijednosti koeficijenta C_p prema normalno distribuiranom procesu

2.1.2 Omjer sposobnosti C_r

Za ocjenu sposobnosti procesa koristi se recipročna vrijednost indeksa C_p :

$$C_r = \frac{6\hat{\sigma}}{T} = \frac{6\hat{\sigma}}{USL - LSL} \quad (6)$$

Ako se iznos ovog indeksa prikaže u postocima ($C_r \cdot 100\%$), dobiva se postotak tolerancijskog područja koji je „iskorišten“ rasponom procesa.

Za sposoban proces iznos indeksa C_r treba biti manji od 1.

2.1.3 Donja i gornja potencijalna sposobnost C_{pL} i C_{pU}

Vrijednosti indeksa C_{pL} i C_{pU} računaju se korištenjem sljedećih izraza:

$$C_{pL} = \frac{(\bar{x} - L)}{3 \cdot \hat{\sigma}} \quad (7)$$

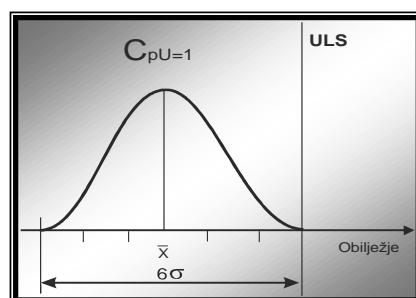
$$C_{pU} = \frac{(U - \bar{x})}{3 \cdot \hat{\sigma}} \quad (8)$$

Sredina procesa je središnja linija primijenjene kontrolne karte. U slučaju računanja statističkih parametara iz svih podataka sredina procesa odgovara aritmetičkoj sredini tih podataka.

Indeksi C_p i C_r ne pokazuju kako je smješten proces u odnosu na granice specifikacija. To se može utvrditi usporedbom iznosa indeksa C_{pL} i C_{pU} :

- identični iznosi ukazuju na potpunu centriranost procesa (vrijednosti indeksa jednake su vrijednostima indeksa C_p)
- iznos manji od 1 ukazuje na nesukladnost
- proces je pomaknut prema granici specifikacije manje vrijednosti indeksa

Ovi indeksi se računaju u slučaju procjenjivanja sposobnosti procesa kada je dan jednostrani zahtjev na proces (samo jedna granica specifikacije-primjer pokazuje sliku 3).

**Slika 3.** Primjena $C_{pL}; C_{pU}$ kad je dan jednostrani zahtjev

2.1.4 Faktor korekcije necentriranosti k

Iznos indeksa C_p može se korigirati zbog necentriranosti računanjem faktora korekcije necentriranosti k :

$$k = \frac{|M - \bar{x}|}{(USL - LSL)/2}, \quad (9)$$

gdje je M ciljana vrijednost procesa, odnosno:

$$M = (USL - LSL)/2; \quad (10)$$

tako da je $0 < k < 1$

2.1.5 Demonstrirana izvrsnost - C_{pk}


Vidjelo se da indeks C_p mjeri potencijalnu sposobnost, pretpostavljajući da je prosjek procesa jednak srednjoj točki granica tolerancije i da se odvija pod statističkom kontrolom. Budući da prosjek nije često u srednjoj točki, korisno je imati indeks sposobnosti koji odražava varijaciju i položaj prosjeka procesa. Takav indeks je C_{pk} . Faktor C_{pk} iskazuje točnost procesa na osnovi najlošije slike podataka (slika 4).

Negativna vrijednost C_{pk} ukazuje da je srednja vrijednost izvan granica tolerancije. Ako je $C_{pk} = 0$ onda je srednja vrijednost jednaka jednoj od granica tolerancije. C_{pk} između 0 i 1,0 znači da proces (6σ) izlazi izvan granica tolerancije. C_{pk} od 1,0 znači da jedan kraj procesa (6σ) pada na granicu tolerancije. C_{pk} iznad 1,0 znači da proces ulazi potpuno unutar granica tolerancije. Što je veća vrijednost C_{pk} , to će biti manja količina proizvoda koji su izvan dopuštenih granica.

Veza između indeksa C_p i C_{pk} matematički se prikazuje kao:

$$C_{pk} = C_p(1-k) \quad (11)$$

gdje je „ k “ vrijednost koja označava koliko je proces odmaknut od centra, a matematički se izražava:



Slika 4. Demonstrirana izvrsnost C_{pk}

Ako je proces idealno centriran tada je k jednak nuli i $C_{pk} = C_p$. Pomicanjem procesa od ciljane vrijednosti

(sredine područja tolerancija) k se povećava, a C_{pk} postaje manji od C_p .

Ako se vrijednost C_{pk} povećava, to zahtjeva promjenu u prosjeku procesa, procesnom standardnom odstupanju ili objema vrijednostima. Za neke procese može biti lakše povećati vrijednost C_{pk} mijenjanjem prosječne vrijednosti (pomoću jednostavnog prilagođavanja procesnom cilju), nego smanjivanjem standardnog odstupanja (istraživanjem mnogih uzroka varijacija). Histogram procesa treba uvijek kritički analizirati kako bi se naglasio prosjek i raspon procesa. Treba biti oprezan te imati na umu da se vrijednosti C_{pk} i C_p izračunavaju za procese s normalnom razdiobom, ali svi procesi se ne ponašaju prema zakonu normalne razdiobe. Bez poznавanja razdiobe kojom se može opisati proces, upotreba C_{pk} vrijednosti može nepravilno utjecati na procjenu i dovesti do loših poslovnih odluka.

Sadašnji standardi za indekse sposobnosti procesa su:

$$C_p > 1,33 \quad \text{i} \quad C_{pk} > 1,33$$

Ova vrijednost nije izabrana slučajno. Procesi su vrlo rijetko staticni i ova vrijednost omogućuje male pomake procesa. Npr., ako se vrijednost C_{pk} mijenja s vrijednosti 1,0 na vrijednost 0,67 (pomak od jedne standardne devijacije), opis procesa se promjeni s 0,27 % škarta na 4,55 % škarta. Također, stvarni procesi obično pridonose povećanju škarta pa visoki indeksi sposobnosti procesa osiguravaju prihvatljivost do kraja linije C_{pk} .

2.2 Preliminarna sposobnost procesa

Preliminarno procjenjivanje sposobnosti procesa provodi se na njegovom početku ili nakon kratkog praćenja procesa. Preporuka je da se razmatra uzorak od najmanje 100 jedinica ili kontrolna karta s najmanje 20 uzoraka.

U nazivlju indeksa se umjesto riječi sposobnost (Capability) koristi termin značajka (Performance). U tom smislu se indeksi označavaju kao P_p , P_{pL} , P_{pU} , P_{pk} , a računaju se na isti način kao C_p , C_{pL} , C_{pU} , C_{pk} , a standardno odstupanje naziva se „ukupno standardno odstupanje“ (engl. overall or total standard deviation).

Zahtjevi na najmanje iznose indeksa P_p i P_{pk} su stroži nego za iznose indeksa C_p i C_{pk} (npr., ako je zahtjev za $C_p \geq 1,33$, tada je ekvivalentni zahtjev za $P_p \geq 1,67$). U SPC softverima za računanje ovih indeksa koristi se ukupno standardno odstupanje.

Ukupno standardno odstupanje računa se iz izraza:

$$s = \hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (12)$$

2.3 Sposobnost u kratkom vremenskom razdoblju

Za analizu sposobnosti procesa u kratkom vremenskom razdoblju često se koristi termin „analiza sposobnosti stroja“ (engl. Machine Capability Analysis). Primjenjuje se prilikom preuzimanja stroja. Preporučuje se analiza na uzorku od najmanje 50 jedinica. Temeljni interes je informacija o rasipanju podataka oko ciljane vrijednosti M .

$$M = \frac{(USL + LSL)}{2} \quad (13)$$

2.3.1 Potencijalna sposobnost stroja C_{pm}

Neki kažu (Boyles 1991.) da C_p i C_{pk} nisu primjereni za opisivanje centriranja procesa. Taguchi zagovara alternativu, a kasnije mnogi autori C_{pm} navod kao Taguchi indeks (Chan 1988.).

C_{pm} se računa korištenjem alternativne procjene standardnog odstupanja koja sadrži efekt slučajne necentriranosti (rasipanja oko ciljane vrijednosti), odnosno:

$$C_{pm} = \frac{T}{6\hat{\sigma}} = \frac{USL - LSL}{6\hat{\sigma}} \quad (14)$$

gdje je:

$$\hat{\sigma} = \sqrt{\sum_{i=1}^n \frac{(x_i - M)^2}{n-1}} \quad (15)$$

Veza C_{pm} kruži oko Taguchijevog šampionskog pristupa smanjenju varijacije s ciljane vrijednosti kao vodeći princip prema poboljšanju kvalitete. Ova jednadžba je dosljedna s Taguchijevom filozofijom, relativna je njegovoj funkciji gubitka i njegovoj filozofiji gubitka financija gdje su žrtve korisnici i društvo općenito, kada proizvod ne postigne željeni cilj. Ovi koncepti opisani su u dalnjem tekstu. Iz ove jednadžbe zapažamo sljedeće:

- više važnosti pridaje se cilju (M)
- manje važnosti pridaje se granicama specifikacija

Pored opisanih pokazatelja sposobnosti procesa, treba navesti da postoji još nekoliko pokazatelja uspješnosti procesa, koji se ovdje neće razmatrati zato što nemaju široku primjenu u industriji.

2.4 Razlozi za primjenu indeksa sposobnosti procesa

Sve veća primjena indeksa sposobnosti procesa u vodećim poduzećima u svijetu može se pojasniti na sljedeći način:

1. Razvoj suvremenog pristupa upravljanju kvalitetom sve više u prvi plan stavlja probleme varijabilnosti konkretnih vrijednosti, tj. odstupanja parametara proizvoda od zadanih

vrijednosti. U suvremenom svijetu ovo je glavni uvjet konkurentne sposobnosti, a pokazatelji sposobnosti procesa služe kao prikladna mjera varijabilnosti procesa.

2. Inzistiranje na certifikaciji i atestiranju proizvoda zahtjeva postojanje kvantitativnih karakteristika deklarirane kvalitete. Za tu namjenu indeksi sposobnosti procesa su najjednostavniji i najjeftiniji.
3. Indeksi sposobnosti procesa su prikladni za suvremeni audit procesa, tj. za periodičku provjeru usklađenosti nekog procesa s definiranim zahtjevima.
4. Provjera sredstava u eksploataciji, njihovo podešavanje, kontrola, održavanje i dr. zahtjeva jednostavne kvantitativne pokazatelje stabilnosti karakteristika kroz određeni vremenski period, za što su također veoma prikladni indeksi sposobnosti procesa.
5. Indeksi sposobnosti procesa prikladni su za praćenje, izbor i ocjenu dobavljača, a pomoću njih se mogu postavljati zahtjevi dobavljačima i tako se stimulira njihov razvoj.
6. Istu ulogu mogu imati indeksi sposobnosti procesa pri interakciji s korisnicima i kupcima. Danas je sve teže prodati proizvode za koje se ne znaju indeksi sposobnosti procesa proizvodnje.
7. Indeksi sposobnosti procesa su odlično sredstvo za kontrolu stanja tehnoloških procesa i prikladna mjera za njihovo poboljšanje.
8. Možda je jedna od najvažnijih osobina indeksa sposobnosti procesa što omogućuje svim sudionicima u procesu (od dobavljača do kupca, od radnika do menadžera) da o problemima kvalitete govore istim jezikom, što je neophodan uvjet za dostizanje suvremene kvalitete proizvoda.

Kod indeksa sposobnosti procesa postoje i nedostaci. Navode se dva najvažnija. To je prije svega jednostavno usklađivanje sa zahtjevima prema određenoj vrijednosti indeksa, jednostavnom izmjenom vrijednosti USL i LSL u tehničkoj dokumentaciji, bez aktivnosti u stvarnoj proizvodnji. Proizvoljno određivanje i korigiranje tolerancije je najveći problem primjene ovih indeksa. Tolerancija se izračunava ili određuje na osnovi σ . Tolerancija se mijenja samo ako se u procesima mijenjaju parametri (npr. broj ljudi, novi stroj i dr) jer se smanjuje σ , što automatski utječe na smanjenje tolerancije. Postoji mogućnost da se ne primijete ozbiljni nedostaci proizvoda, oslanjajući se na visoke vrijednosti indeksa sposobnosti procesa u slučaju nepotpunog razumijevanja dopuštenih odstupanja, na kojima se zasniva njihova točna primjena.

3. EKSPERIMENTALNI REZULTATI

Za obradu i daljnju analizu koristi se programski paket „Statistica“. Software je razvila američka tvrtka Statsoft Inc. i sadrži napredne alate za statističku, grafičku i analitičku obradu podataka te specijalizirane alate i metode za analiziranje podataka i kontrole kvalitete. Statistica je ujedno i analitička platforma koja više od dva desetljeća doprinosi znanstvenim otkrićima te potpomaže uspješne poslovne rezultate svojih korisnika. U hrvatskim ustanovama iz sustava visoke naobrazbe i znanosti Statistica se koristi u nastavi, kao i u znanstvenom i istraživačkom radu još od kraja 90-tih godina, a danas broji preko 2000 korisnika.

Za analizu je uzeto 90 podataka iz završne kontrole u proizvodnji stretch folije a parametri za praćenje bili su:

- Sposobnost procesa proizvodnje stretch folije na temelju varijable debljine
- Sposobnost procesa proizvodnje stretch folije na temelju varijable predzatezanja
- Sposobnost procesa proizvodnje stretch folije na temelju varijable zatezanja
- Sposobnost procesa proizvodnje stretch folije na temelju varijable težine

3.1 Sposobnost procesa proizvodnje stretch folije na temelju varijable debljine

Za procjenu sposobnosti procesa proizvodnje stretch folije na temelju varijable debljine, uzete su niže navedene zahtijevane vrijednosti:

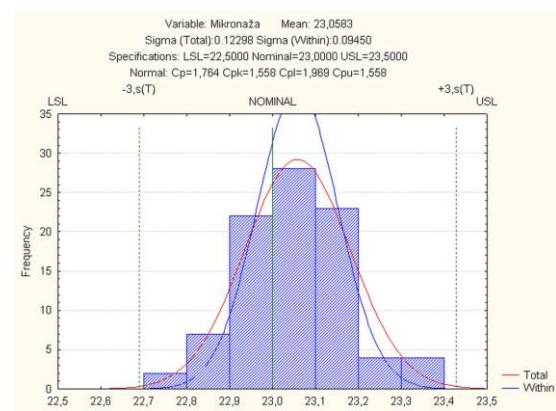
- Nazivna vrijednost debljine: 23 µm
- Gornja granica (USL): 23,5 µm
- Donja granica (LSL): 22,5 µm
- Ciljana mjera: 23 µm

Podatci o uzorkovanju prikazani su u tabeli 2, a rezultati izračuna na slici 5.

Tabela 2. Rezultati uzorka mjerjenja debljine folije

1. dan	2. dan	3. dan	4. dan	5. dan
23,06	22,94	22,91	23,19	22,94
23,08	23,12	23,31	23,08	23,02
23,04	23,14	23,16	23,08	22,87
23,04	23,08	23,18	22,99	23,15
23,09	23,09	23,05	23,09	23,19
23,15	23,2	23,07	23,14	23,23
23,2	22,84	23,08	23,01	23,14
23,16	22,94	23,09	22,75	23,05
23,01	22,85	23,13	23,06	22,92

6. dan	7. dan	8. dan	9. dan	10. dan
23,2	22,97	23,16	23,1	22,85
23,19	23,31	22,92	23,09	22,95
23,06	23,35	22,97	23,07	22,91
23,02	23,15	22,79	23,05	22,96
22,87	23,21	22,99	23,01	22,95
23,07	23,19	23,31	23	23,19
22,89	22,88	23,25	22,97	23,15
22,94	23,21	22,99	22,96	22,98
23,03	23,12	23,14	23	22,97



Slika 5. Histogram debljine folije

Indeks sposobnosti procesa (slika 5) prikazuje kako je proces sposoban: $C_p > 1,33$. Rasipanje procesa iznosi $6s = 0,75 \mu\text{m}$, a tolerantno polje, $USL - LSL = 1$. Cijeli proces je pomaknut prema gornjoj granici zahtjeva – što je zadovoljavajuće, a možemo se očitati iz indeksa $C_{pk} = 1,558$.

3.2 Sposobnost procesa proizvodnje stretch folije na temelju varijable predzatezanja


Za procjenu sposobnosti procesa proizvodnje stretch folije na temelju varijable predzatezanja uzete su niže navedene zahtijevane vrijednosti:

- Nazivna vrijednost predzatezanja: 170
- Gornja granica (USL): 180
- Donja granica (LSL): 160

Podatci o uzorkovanju prikazani su u tabeli 3, a rezultati izračuna na slici 6.

Tabela 3. Rezultati uzorka mjerjenja predzatezanja

1. dan	2. dan	3. dan	4. dan	5. dan	6. dan	7. dan	8. dan	9. dan	10. dan
160	173	165	164	171	174	172	169	180	164
170	172	175	169	164	174	173	168	180	166
180	178	176	180	166	172	174	166	180	171
165	179	179	179	166	179	172	162	176	175
175	180	174	178	163	178	170	161	175	172
180	165	173	172	167	176	170	171	175	173
174	162	172	175	169	165	178	172	172	172
169	161	172	173	175	169	179	178	171	170
164	160	174	172	175	168	176	179	169	172



Slika 6. Histogram predzatezanja

Indeks sposobnosti procesa (slika 6) prikazuje kako je njegova sposobnost upitna $C_p = 1,053$ i kako ga je i dalje potrebno nadzirati. Rasipanje procesa: $6s = 31$; a tolerantno polje, USL – LSL = 20 je veće od zahtijevanog.

Cijeli proces je pomaknut prema gornjoj granici zahtjeva i može se zaključiti da je necentriran.

3.3 Sposobnost procesa proizvodnje stretch folije na temelju varijable zatezanja

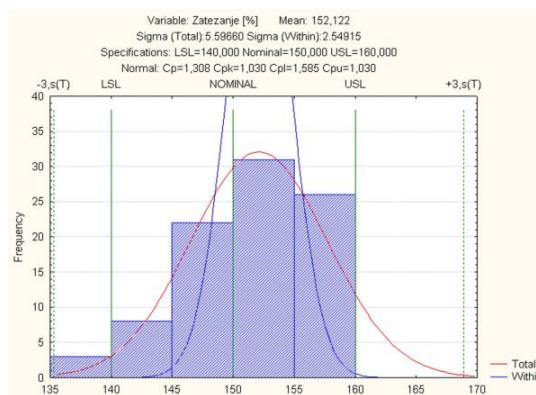
Za procjenu sposobnosti procesa proizvodnje stretch folije na temelju varijable zatezanja uzete su niže navedene zahtijevane vrijednosti:

- Nazivna vrijednost predzatezanja: 150 %
- Gornja granica (USL):160 %
- Donja granica (LSL):140 %

Podatci o uzorkovanju prikazani su u tabeli 4, a rezultati izračuna na slici 7.

Tabela 4. Rezultati uzorka mjerenja zatezanja

1. dan	2. dan	3. dan	4. dan	5. dan
150	140	159	152	149
146	142	153	154	150
160	150	152	149	152
155	157	152	148	153
158	155	152	142	158
153	158	160	142	155
151	160	158	140	150
146	160	160	145	157
141	160	150	146	159
6. dan	7. dan	8. dan	9. dan	10. dan
160	149	158	146	159
154	148	157	148	158
152	152	155	149	160
151	155	152	148	157
151	156	148	150	155
150	157	146	153	154
154	152	142	153	155
146	159	141	154	153
145	160	140	158	152



Slika 7. Histogram zatezanja

Indeks sposobnosti procesa prikazuje kako je njegova sposobnost upitna $C_p = 1,308$ i kako ga je i dalje potrebno nadzirati. Rasipanje procesa: $6s = 33,5$ % ; USL – LSL = 20 % je veće od zahtijevanog.

Cijeli proces je pomaknut prema donjoj granici zahtjeva i necentriran je.

3.4 Sposobnost procesa proizvodnje stretch folije na temelju varijable težine

Za procjenu sposobnosti procesa proizvodnje stretch folije uzete su niže navedene zahtijevane vrijednosti:

- Nazivna vrijednost predzatezanja: 5,00 Kg
- Gornja granica (USL):5,05 Kg
- Donja granica (LSL):4,95 Kg

Podatci o uzorkovanju prikazani su u tabeli 5, a rezultati izračuna na slici 8.

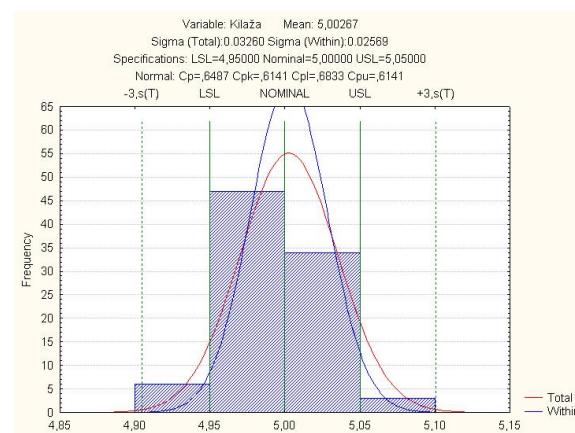
Tabela 5. Rezultati uzorka mjerenja težine

1. dan	2. dan	3. dan	4. dan	5. dan
4,95	5,03	4,97	5,01	4,99
4,99	5,01	5,04	5,05	5,02
5,01	4,99	4,99	4,99	5,03
5	5	5,01	4,96	5
5	4,95	5	5,01	5
5	4,97	5,04	4,96	5
4,96	5,03	4,96	4,97	5
4,98	5,02	5,04	5,04	5
5,05	5	5	5,02	4,97

6. dan	7. dan	8. dan	9. dan	10. dan
4,98	4,95	4,95	4,91	5
4,99	5,05	4,96	5	5,01
5	5,05	5,02	5,02	5,05
5,01	5,08	5,03	5,04	5,09
5,02	5,01	5	5,05	5,08
5,03	4,98	5	5	5
5,05	4,99	5	4,96	5,01
4,99	5,02	5	4,97	4,96
4,98	5,03	4,95	4,99	4,97

Indeks sposobnosti procesa prikazuje kako je njegova sposobnost upitna te kako ga je i dalje potrebno nadzirati.

Rasipanje procesa: $6s = 0,11$ Kg ; USL – LSL = 0,1 Kg i veće je od zahtijevanog.Cijeli proces je necentriran pomaknut prema gornjoj granici zahtjeva.



Slika 8. Histogram težine

4. ZAKLJUČAK

Tijekom procesa proizvodnje stretch folije najveća odstupanja ili varijacije ima varijabla zatezanje. Navedena varijabla prikazuje rastezanje folije po njezinoj dužini, što prvenstveno ovisi o kvaliteti ulazne sirovine, a zatim i o temperaturi taljenja odnosno temperaturi ponovnog hlađenja.

Potrebna je kvalitetnija ulazna kontrola sirovine kako bi se ovakve nepravilnosti ubuduće izbjegle, na način da se nedovoljno kvalitetna sirovina prije ulaska u ekstruder odstrani i vrati dobavljaču. Samim time bi se smanjile i ostale varijacije pošto su usko povezane sa sirovinom.

Neizbjježno je nakon provedenih mjera poboljšanja pratiti proces i što je češće moguće analizirati dobivene vrijednosti u svrhu daljnog usavršavanja i poboljšavanja procesa proizvodnje stretch folije.

Rad je prikazao primjenu statističkih alata u nadziranju i kontroli jednog realnog procesa. Važno je naglasiti da se sposobnost procesa preko indeksa može najbolje pratiti u kombinaciji s kontrolnim kartama i uz korištenjeg kompetentnih programskih alata. Na osnovu praćenja io naliza moguće je poduzimati mjere poboljšanja, odnosno djelovati u području definiranih tolerancija / specifikacija. Primjena ovih alata zahtijeva izobrazbu kadrova (operatera, voditelja smijene, kontrolora i najvišeg vodstva) kako bi se ostvarila efikasna primjena.

4. LITERATURA

- [1] Mudronja V.; Predavanja iz kontrole kvalitete; FSB Zagreb 2010; www.fsb.hr, listopad 2010.
- [2] Kovačić G.; Statistička analiza procesa proizvodnje stretch folije, Završni rad br. 45/PS/2012, Veleučilište u Varaždinu, studij proizvodnog strojarstva, Varaždin, 2012.
- [3] Statistical Process Control (SPC) reference manual; Chrysler Corporation, Ford Motor Company, General Motors Corporation; 1995.
- [4] Kondić Ž.; Statistička kontrola kvalitete, veleučilište u Varaždinu, varaždin, 2012.
- [5] Šakić, N.; Benić, D.; Statistika u kontroli kvalitete, podloge za seminar iz statističke kontrole kvalitete, Zagreb, FSB, laboratorij za operativno istraživanje, 1996.
- [6] Tehnička dokumentacija sustava upravljanja kvalitetom, tvrtke Bomark – Pak d.o.o. Varaždin, 2010.
- [7] HRN ISO/TR 10017:2003, Upute za statističke tehnike za ISO 9001:2000.
- [8] ISO 11462-1:2001, Smjernice za primjenu statističke kontrole postupka (SPC) - 1. dio: Elementi SPC
- [9] ISO/TR 13425:1995, Upute za odabir statističkih metoda u standardizaciji i specifikaciji

Kontakt autora:

Goran Kovačić, ing.strojarstva
Bomark – Pak d.o.o. Varaždin
gkovacic@bomark.hr

Živko Kondić, dr.sc
Veleučilište u Varaždinu
Križanićeva 33
zkondic@velv.hr