

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Dino Budinjaš

Zagreb, 2019. godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Doc. dr. sc. Hrvoje Cajner

Student:

Dino Budinjaš

Zagreb, 2019

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se svojem mentoru doc. dr. sc. Hrvoju Cajneru na ukazanoj stručnoj pomoći, strpljenju i navođenju tijekom izrade ovog rada.

Zahvaljujem se svojim roditeljima i sestri na pruženoj podršci, pomoći i razumijevanju tijekom mojeg akademskog puta.

Dino Budinjaš



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
 Povjerenstvo za diplomske radove studija strojarstva za smjerove:
 proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
 inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **DINO BUDINJAŠ** Mat. br.: **0035200533**

Naslov rada na hrvatskom jeziku: **Analiza mogućnosti potpune automatizacije radnog mjesta**

Naslov rada na engleskom jeziku: **Analysis of possibility of complete automation of work station**

Opis zadatka:

Nakon analize isplativosti zamjene postojećeg radnog mjesta za tvrdo tokarenje automatiziranim rješenjem potrebno je implementirati sustav verificirati. Analizom vremena, učestalosti zastoja i kvalitete implementiranog rješenja moguće je utvrditi opravdanost investicije. Kao sljedeći korak ka potpunoj automatizaciji radnog mjesta potrebno je minimizirati intervencije operatera ne samo u fazi samog tvrdog tokarenja već i u fazi kontrole sukladnosti proizvoda.

U radu je potrebno:

1. Opisati implementirano automatizirano rješenje.
2. Prikupiti podatke o vremenima izrade, produktivnosti, zastojima i kvaliteti izlaznog proizvoda te kvantificirati poboljšanje.
3. Analizirati mogućnost proširenja automatske kontrole dimenzija i akvizicije podataka te predložiti rješenje.
4. Razviti algoritam za statističku kontrolu procesa uzimajući specifičnosti radnog mjesta.
5. Usporediti postojeće i predloženo rješenje preko ključnih pokazatelja performansi procesa.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:
02. svibnja 2019.

Rok predaje rada:
04. srpnja 2019.

Predviđeni datum obrane:
10. srpnja 2019.
11. srpnja 2019.
12. srpnja 2019.

Zadatak zadao:
doc. dr. sc. Hrvoje Čajner

Predsjednica Povjerenstva:
prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	IV
POPIS OZNAKA	V
SAŽETAK.....	VII
SUMMARY	VIII
1. UVOD.....	1
2. IMPLEMENTIRANO AUTOMATIZIRANO RJEŠENJE.....	3
2.1. Opis realiziranog rješenja.....	3
2.2. Kontrola kvalitete.....	4
2.3. Usporedba automatiziranog rješenja i posluživanja operatera.....	4
2.4. Moguća unaprjeđenja radnog mjesta	6
3. TEORIJA STATISTIČKE KONTROLE PROCESA	7
3.1. Definicija.....	7
3.1.1. Kvaliteta.....	7
3.1.2. Proces	7
3.2. Kontrolne karte	8
3.2.1. Značajke	8
3.2.2. Ciljevi.....	9
3.3. Sposobnost procesa	10
3.3.1. Indeksi sposobnosti procesa.....	11
4. SPOSOBNOST POSTOJEĆEG PROCESA	15
4.1. Karakteristike dimenzije i uzorka	15
4.2. Indeksi sposobnosti procesa analiziranog uzorka	17
4.2.1. Osnovni uvjet sposobnosti procesa	17
4.2.2. Potencijalna sposobnost procesa	17
4.2.3. Demonstrirana izvrsnost	17
4.3. Dodatni histogram i demonstrirana izvrsnost	18
5. AUTOMATSKA KONTROLA DIMENZIJA I AKVIZICIJA PODATAKA	20
5.1. Odabir dimenzije.....	20
5.2. Povezanost dimenzija.....	21
5.2.1. Odnos dimenzije D_2 i D_3	21
5.2.2. Odnos dimenzije D_2 i dimenzija L_2 i L_3	24
5.3. Odabir kontrolne karte	24
5.4. Postavljanje kontrolne karte.....	26
5.5. Kontrola pomoću postojeće mjerne sonde	27
5.5.1. Mjerna sonda Marposs VOP40L	28
5.5.2. Potprogram za mjerenje	28
5.5.3. Vanjsko računalo i monitor	29
5.6. Kontrola izvan stroja.....	30

5.6.1.	Robot ABB IRB 1200	30
5.6.2.	Naprava za mjerenje vijaka	31
5.6.3.	Sustav za mjerenje	34
5.6.4.	Potprogram robota za postavljanje vijaka u napravu	34
5.6.5.	Vanjsko računalo i monitor	35
6.	APLIKACIJA ZA STATISTIČKU KONTROLU PROCESA	36
6.1.	Opseg aplikacije	36
6.2.	Struktura Excel datoteke	37
6.3.	Korisničko sučelje	39
6.3.1.	Novo mjerenje	39
6.3.2.	Uređivanje parametara	40
6.3.3.	Dodavanje proizvoda	41
6.4.	Korištenje aplikacije	41
6.5.	Programski kod aplikacije	43
7.	USPOREDBA POSTOJEĆEG I PREDLOŽENOG RJEŠENJA	45
7.1.	Odabir pokazatelja	45
7.2.	Vrijeme intervencije operatera	46
7.3.	Informiranost o procesu	47
7.4.	Udio kontroliranih proizvoda	48
7.5.	Iskorištenost robota	49
8.	ZAKLJUČAK	50
	LITERATURA	52
	PRILOZI	54

POPIS SLIKA

Slika 1.	Tlocrt radnog mjesta.....	3
Slika 2.	Automatizirano rješenje u pogonu poduzeća	4
Slika 3.	Usporedba produktivnosti	6
Slika 4.	Shematski prikaz procesa proizvodnje [5]	8
Slika 5.	Opći izgled kontrolne karte	8
Slika 6.	Proces u stanju statističke kontrole [5].....	9
Slika 7.	Nestabilan proces (točka izvan kontrolnih granica, trend) [5]	9
Slika 8.	Nestabilan proces (ciklički trend, jednostranost) [5].....	9
Slika 9.	Sposobnost procesa [6].....	10
Slika 10.	Procesi niske, srednje i visoke kvalitete [6]	11
Slika 11.	Površina tri standardne devijacije od očekivane vrijednosti [10].....	12
Slika 12.	Proces izvan centra [6]	13
Slika 13.	Histogram procesa na postojećem radnom mjestu	16
Slika 14.	Histogram procesa prikazan pomoću druge dimenzije	18
Slika 15.	Obradene površine vijaka.....	20
Slika 16.	Dijagram rasipanja D_2 i D_3	23
Slika 17.	Kretanje vrijednosti D_2 i D_3 u uzorku	23
Slika 18.	Odabir kontrolne karte [5].....	25
Slika 19.	Primjer X/MR kontrolne karte	26
Slika 20.	Mjerna sonda Marposs VOP40L.....	28
Slika 21.	Primjer potprograma za automatsko mjerenje vijaka.....	29
Slika 22.	Naprava za mjerenje konusa držača alata [15].....	31
Slika 23.	Vizualizacija naprave za mjerenje vijaka	32
Slika 24.	Komponente naprave za mjerenje	33
Slika 25.	Dodir mjerne sonde i vijka	33
Slika 26.	Inicijalizacijski prozor aplikacije	36
Slika 27.	Dijagram toka aplikacije	36
Slika 28.	Radni listovi aplikacije.....	37
Slika 29.	Mjerni list aplikacije po završetku mjerenja	38
Slika 30.	Početni prozor aplikacije	39
Slika 31.	Prozor za unos podataka za novo mjerenje	40
Slika 32.	Prozor za uređivanje parametara vijaka	40
Slika 33.	Prozor za dodavanje novog vijka	41
Slika 34.	Glavni prozor aplikacije za praćenje proizvodnje	42
Slika 35.	Programski kod postavljanja novog procesa	43
Slika 36.	Uštedeno vrijeme operatera implementacijom predloženih rješenja	47
Slika 37.	Povećanje udjela kontroliranih proizvoda	48
Slika 38.	Smanjenje potencijalno nesukladnih proizvoda	49

POPIS TABLICA

Tablica 1. Stanje prije automatizacije	5
Tablica 2. Predviđeno stanje poslije automatizacije	5
Tablica 3. Realna produktivnost nakon automatizacije.....	6
Tablica 4. Preporučene vrijednosti Cp [16].....	13
Tablica 5. Karakteristike dimenzije za analizu procesa	15
Tablica 6. Deskriptivna statistika uzorka	15
Tablica 7. Stanje obrade prije i poslije promjene procesa.....	21
Tablica 8. Korelacijska analiza dimenzija D2 i D3.....	22
Tablica 9. Značajke VOP40L	27
Tablica 10. Specifikacije ABB IRB 1200 [12].....	31
Tablica 11. Karakteristike mjerne sonde [13]	34
Tablica 12. Glavane zadaće aplikacije	37
Tablica 13. Parametri pojedinih vijaka unutar radnog lista.....	38
Tablica 14. Usporedba postojećeg i predloženog rješenja u vremenu intervencije operatera .	46
Tablica 15. Usporedba postojećeg i predloženog rješenja prema informiranosti o procesu	47
Tablica 16. Usporedba postojećeg i predloženog rješenja prema udjelu kontroliranih vijaka.	48
Tablica 17. Usporedba postojećeg i predloženog rješenja prema utilizaciji robota.....	49

POPIS OZNAKA

Oznaka	Jedinica	Opis
T	mm	Tolerancijski raspon
USL	mm	Gornja granica tolerancije
LSL	mm	Donja granica tolerancije
C_p	-	Potencijalna sposobnost procesa
C_{pk}	-	Demonstrirana izvrsnost
MR	mm	Kretajući raspon
\bar{x}	mm	Aritmetička sredina vrijednosti mjerenja
σ	mm	Standardna devijacija
σ^2	mm	Varijanca
R	mm	Raspon vrijednosti
\bar{R}	mm	Aritmetička sredina kretajućih raspona
S_{MR}	mm	Standardna devijacija prema kretajućim rasponima
n	-	Veličina uzorka
r	-	Pearsonov koeficijent korelacije
r^2	-	Koeficijent determinacije
α	-	Razina značajnosti
p	-	p-vrijednost
CPS	-	Cyber Physical Systems
t_{t_prije}	s	Tehnološko vrijeme prije automatizacije
t_{p_prije}	s	Pomoćno vrijeme prije automatizacije
n_{kom/h_prije}	-	Prosječni broj komada po satu prije automatizacije
$n_{kom_smj_prije}$	-	Prosječni broj komada po smjeni prije automatizacije
$t_{t_pred_poslije}$	s	Predviđeno tehnološko vrijeme poslije automatizacije
$t_{p_pred_poslije}$	s	Predviđeno pomoćno vrijeme poslije automatizacije
$n_{kom/h_pred_poslije}$	-	Prosječni predviđeni broj komada po satu poslije automatizacije
$n_{kom_smj_pred_poslije}$	-	Prosječni predviđeni broj komada po smjeni poslije automatizacije
$t_{t_poslije}$	s	Tehnološko vrijeme nakon automatizacije

<i>t_{p_poslije}</i>	s	Pomoćno vrijeme nakon automatizacije
<i>n_{kom/h_poslije}</i>	-	Prosječni broj komada po satu poslije automatizacije
<i>n_{kom_smj_poslije}</i>	-	Prosječni broj komada po smjeni poslije automatizacije

SAŽETAK

Tema ovog rada je analiza mogućnosti potpune automatizacije radnog mjesta za završnu obradu u procesu proizvodnje povlačnih vijaka poduzeća SAB d.o.o. Radno mjesto je nedavno robotizirano te se prvo analizira implementirano automatizirano rješenje kako bi se utvrdilo jesu li ostvarene očekivane prednosti. Poslije toga su pobliže objašnjeni temeljni pojmovi statističke kontrole procesa, a zatim je analizirana sposobnost postojećeg procesa na promatranom radnom mjestu. Glavni dio rada predstavlja dva predložena rješenja za automatizaciju procesa kontrole kvalitete te aplikaciju za statističku kontrolu procesa koja je razvijena za potrebe radnog mjesta. Na kraju rada su uspoređena predložena rješenja s postojećim stanjem radnog mjesta te je iznesen zaključak rada.

Ključne riječi: statistička kontrola procesa, automatizacija kontrole kvalitete, unaprjeđenje procesa, pametna tvornica

SUMMARY

The purpose of this thesis is the analysis of possibility of complete automation of work station which serves as a final step in pull stud manufacturing proces in company SAB d.o.o. Work station has recently been robotized so first is the implemented automated solution analysed to find out if expected benefits have been met. Then are the key terms of statistical process control explained and current process capabilty is analysed. Main part of the thesis presents two proposed solutions for automation of quality control and an application for statistical process control which has been developed for the work station. Finally, proposed solutions are compared to the existing state of work station and conclusion is presented.

Key words: statistical process control, quality control automation, process improvement, smart factory

1. UVOD

Riječ *automatizacija* je danas jedna od često korištenih riječi u mnogim industrijama, a posebice u proizvodnji. Definirati se može kao korištenje tehnologije, strojeva i opreme u svrhu zamjene i smanjenja ljudskog rada pri različitim procesima. Automatiziranjem procesa ostvaruju se mnoge prednosti – povećanje produktivnosti, smanjenje ljudskih intervencija, viša kvaliteta procesa, itd. No automatizacija je samo dio šireg pojma pod nazivom Cyber Physical Systems koji je ključan za Industriju 4.0 odnosno trenutnu industrijsku revoluciju unutar koje se nalazimo. CPS je automatizirani sustav koji omogućava povezivanje operacija koje se odvijaju u realnom svijetu s računalnom i komunikacijskom infrastrukturom. Glavna značajka ovih sustava je razmjena podataka s drugim sustavima, a pogotovo putem interneta gdje se u tom slučaju taj CPS naziva „Internet of Things“. Implementacija ovih sustava u proizvodna poduzeća postiže se glavni cilj Industrije 4.0 – pretvorba tvornica u pametne tvornice[1]. CPS omogućava poduzećima nove mogućnosti poboljšanja postojećih procesa i uvođenje potpuno novih procesa poput automatizirane akvizicije podataka sa strojeva u proizvodnom procesu. Ti podaci su dio koncepta Big Data gdje se koriste za Big Data analitiku koja povećava proizvodnu efikasnost poboljšanjem održavanja opreme, smanjenjem energetske troškova i povećanjem kvalitete [2]. Uz korištenje odgovarajućih algoritama za analitiku podataka omogućavaju poduzećima pristup dosad nedohvatljivim informacijama i znanju za strateško donošenje odluka. Upravo takvo donošenje odluka potkrepljeno kvalitetnim informacijama koje su dobivene u pravo vrijeme poduzećima omogućuje priliku za rast na svim područjima – od operativne efikasnosti do ekonomskih i tržišnih uspjeha. Postavlja se pitanje koji motiv stoji iza prethodno nabrojanih pojmova i općenito četvrte industrijske revolucije? Pokretačke sile koje stoje iza Industrije 4.0 su razne socio-ekonomske i političke promjene u svijetu, točnije:

- Smanjenje ciklusa razvoja: ciklusi razvoja i inovacija se moraju skratiti jer je visoka sposobnost inoviranja ključni faktor uspjeha na tržištu mnogih poduzeća
- Individualizacija: poduzeća već godinama prelaze iz tržišta „prodavača“ u tržište „kupaca“ gdje kupci određuju uvjete trgovanja. To dovodi do veće individualizacije proizvoda prema zahtjevima kupaca, odnosno do serija veličine jednog komada
- Fleksibilnost: obzirom na prethodno nabrojane zahtjeve, potrebna je veća fleksibilnost u razvoju i proizvodnji proizvoda

-
- Decentralizacija: danas je potrebno puno brže donositi odluke, a kako bi se taj zahtjev udovoljio potrebna je smanjena organizacijska hijerarhija
 - Efikasno korištenje resursa: smanjenje dostupnih resursa i s tim u vezi povećanje cijena te također društvene promjene u vezi ekoloških aspekata zahtijevaju intenzivniji fokus na održivost u industriji. Cilj je povećanje ekonomske i ekološke efikasnosti [3].

Poduzeća koja žele ostati konkurentna stoga moraju biti spremna odgovoriti na ove zahtjeve, a koncept Industrije 4.0 uz automatizaciju, CPS, i Big Data je jedan od odgovora.

U završnom radu [4] „Usporedba postojećeg radnog mjesta s budućim predloženim automatiziranim rješenjem“ opisano je radno mjesto i proces proizvodnje poduzeća SAB d.o.o. koje je željeno automatizirati, opisano je automatizirano rješenje, te je odgovoreno na pitanje isplativosti takve investicije. U međuvremenu je radno mjesto automatizirano i koristi se već nekoliko mjeseci u poduzeću. Nakon inicijalnog perioda obučavanja, uhodavanja i dječjih bolesti konačno je moguće analizirati automatizirano rješenje nakon implementacije i usporediti s predviđanjima iz završnog rada, odnosno utvrditi opravdanost investicije.


Ovaj rad je nastavak spomenutog završnog rada i kao takav osim analize opravdanosti investicije ponudit će i određena rješenja u vidu daljnjeg povećanja stupnja automatizacije radnog mjesta.. Glavni razlog što je trenutno i dalje potrebna učestala ljudska intervencija na radnom mjestu je kontrola kvalitete. Cilj je svesti ljudsku intervenciju na radnom mjestu na minimum, naravno bez utjecaja na kvalitetu i produktivnost samog procesa. Iz tog razloga se u radu izlaže mogućnost automatiziranja procesa kontrole kvalitete i prikupljanja podataka korištenjem senzora uz implementaciju alata statističke kontrole procesa, gdje se podaci dobiveni na ovaj način analiziraju korištenjem razvijenog algoritma unutar aplikacije. Time se postiže efikasnije korištenje resursa poduzeća uporabom CPS-a, čime je poduzeće korak bliže pametnoj tvornici, odnosno Industriji 4.0.

2. IMPLEMENTIRANO AUTOMATIZIRANO RJEŠENJE

Krajem 2018. godine u poduzeću SAB d.o.o. implementirano je prvo automatizirano rješenje za radno mjesto tvrdog tokarenja povlačnih vijaka. U nastavku se opisuje samo rješenje i njegova realizacija u pogonu poduzeća, uspoređuju se podaci iz studije isplativosti investicije s podacima iz realnih uvjeta, te se iz istih izvode zaključci.

2.1. Opis realiziranog rješenja

Automatizirano rješenje je uvedeno na radnom mjestu koje služi obavljanju završne operacije u proizvodnji povlačnih vijaka, odnosno tvrdom tokarenju. Rješenje se sastoji od modularnog postolja sa zaštitom, robota ABB IRB 1200, stezne naprava s dvije prihvatnice Schunk, te paletnog spremnika za obratke s četiri palete.



Slika 1. Tlocrt radnog mjesta

Na slici 1 prikazana je robotska ćelija pomoću koje se poslužuje tokarilica SPINNER TS. Stroj se poslužuje povlačnim vijcima tipa PV16 i PV24, odnosno obrađuju se dvije skupine vijaka. Vijke koje je potrebno obraditi na ovom radnom mjestu je prvo potrebno posložiti u paletne spremnike iz kojih robot izuzima vijke. Spomenuti paletni spremnik se sastoji od četiri palete, od kojih su dvije ulazne, a dvije izlazne. Ovisno o vrsti vijaka kapacitet spremnika je 280 vijaka za vrstu PV24 ili 552 vijaka za vrstu PV16.



Slika 2. Automatizirano rješenje u pogonu poduzeća

Kada su vijci posloženi u paletni spremnik moguće je započeti proces obrade. Robot izuzima vijak iz palete i postavlja ga u steznu napravu na stroju, nakon čega započinje obrada. Tijekom obrade robot odlaže obrađeni vijak u izlaznu paletu i izuzima novi vijak za obradu iz ulaznog spremnika, čime se završava ciklus posluživanja robota.

2.2. Kontrola kvalitete

Poput većine ostalih radnih mjesta u poduzeću, kontrola kvalitete se vrši na samom radnom mjestu. Robot se može konfigurirati da izuzima svaki n-ti vijak za kontrolu kvalitete. Trenutno se izuzima svaki osmi vijak, kojeg potom operater mjeri i određuje sukladnost zadanim tolerancijama. Na većini proizvoda je potrebno izmjeriti dva promjera pomoću mikrometra i dvije duljinske mjere pomoću visinomjera. Nakon mjerenja se po potrebi unose korekcije i zapisuju se rezultati mjerenja kao točke na X kontrolnoj karti. Kontrolna karta služi kao smjernica za odlučivanje o poduzimanju korektivnih radnji ukoliko se izmjerena značajka nalazi izvan područja postavljenih kontrolnih granica te se koristi i za praćenje trendova.

2.3. Usporedba automatiziranog rješenja i posluživanja operatera

U prethodnom radu [4] je analizirano radno mjesto prije automatizacije prikupljanjem podataka iz dnevnika rada. Na taj način su dobiveni podaci o produktivnosti, vremenima obrade, pripreme i slično. Analiziran je uzorak od 56 smjena, a dobiveni su sljedeći podaci:

Tablica 1 Stanje prije automatizacije

Oznaka:	Opis:	Vrijednost:
t_{t_prije}	Tehnološko vrijeme	34,89 s
t_{p_prije}	Pomoćno vrijeme	58,02 s
n_{kom/h_prije}	Prosječni broj komada po satu prije automatizacije	32,65
$n_{kom_smj_prije}$	Prosječni broj komada po smjeni prije automatizacije	261

Podaci iz tablice 1 su izračunati prosjeci podataka iz uzorka. Prosječni broj komada po satu prije automatizacije je omjer ukupnog broja obrađenih vijaka u uzorku i broja sati potrošenih za to. Prosječni broj komada po smjeni prije automatizacije se računa za smjenu od 8h. I u prethodnom radu je zaključeno kako se tehnološko vrijeme neće promijeniti uvođenjem automatiziranog rješenja, već će najveća promjena biti kod pomoćnog vremena, a shodno s time i produktivnost. Neki od utjecajnih faktora duljine pomoćnog vremena su izmjena i manipulacija obradcima, kontrola kvalitete, neplanirani zastoji, zamor operatera, itd.

Osim analize prije automatizacije u prethodnom radu su predviđena i poboljšanja produktivnosti nakon automatizacije na temelju dostupnih podataka i određenih pretpostavki:

Tablica 2. Predviđeno stanje poslije automatizacije

Oznaka:	Opis:	Vrijednost:
$t_{t_pred_poslije}$	Tehnološko vrijeme	34,89 s
$t_{p_pred_poslije}$	Pomoćno vrijeme	15 s
$n_{kom/h_pred_poslije}$	Prosječni predviđeni broj komada po satu poslije automatizacije	49,7
$n_{kom_smj_pred_poslije}$	Prosječni predviđeni broj komada po smjeni poslije automatizacije	398


Pomoćno vrijeme je određeno na temelju specifikacije dobavljača automatiziranog rješenja, a prema tome su predviđeni i ostale vrijednosti iz tablice 2. U podacima o produktivnosti uračunat je i faktor sigurnosti za dodatne neplanirane zastoje robota u iznosu od 10%.

Kako je samo rješenje već nekoliko mjeseci u radu u pogonu poduzeća, na isti način se analizira realno stanje produktivnosti pomoću dnevnika rada operatera. Na uzorku od 45 smjena dobiveni su sljedeći podaci:

Tablica 3. Realna produktivnost nakon automatizacije

Oznaka:	Opis:	Vrijednost:
$t_{t_poslije}$	Tehnološko vrijeme	34,89 s
$t_{p_poslije}$	Pomoćno vrijeme	20 s
$n_{kom/h_poslije}$	Prosječni broj komada po satu poslije automatizacije	41,34
$n_{kom_smj_poslije}$	Prosječni broj komada po smjeni poslije automatizacije	331

Dobiveni podaci u realnim uvjetima se razlikuju od podataka prije automatizacije, ali i od podataka koji su predviđeni u prethodnom radu. U odnosu na razdoblje prije automatizacije može se zaključiti kako je došlo do porasta produktivnosti u iznosu od 26,82%. Isto tako, produktivnost u realnim uvjetima je 20,24% manja u odnosu na predviđenu produktivnost nakon uvođenja automatizacije. Neki od razloga za potonju razliku su niski udio visoko-serijskog posla, uhodavanje operatera, razina optimizacije procesa, različito pomoćno vrijeme od predviđenog, itd. Na primjer, trenutno kada se obrađuju velike serije proizvoda moguće je ostvariti i preko 500 obrađenih komada po smjeni. Ipak, očito je povećana produktivnost u odnosu na stanje prije implementacije automatiziranog rješenja.



Slika 3. Usporedba produktivnosti

2.4. Moguća unaprjeđenja radnog mjesta

Unatoč značajnoj automatizaciji radnog mjesta i dalje postoji potreba kontinuirane intervencije operatera na radno mjesto, a razlog tomu je kontrola kvalitete. Stoga se potpuna automatizacija radnog mjesta, odnosno automatizacija kontrole kvalitete nameće kao logičan smjer daljnjeg unaprjeđenja radnog mjesta. Uz to, automatizacijom procesa mjerenja i prikupljanja podataka nastaju izvrsni uvjeti za uvođenje statističke kontrole procesa. Ovim poboljšanjima se smanjuje potreba za intervencijama operatera, te se omogućava uspješnije praćenje, upravljanje i analiza procesa kako bi proces bio stabilniji uz što manje varijacija.

3. TEORIJA STATISTIČKE KONTROLE PROCESA

3.1. Definicija

Statističku kontrolu procesa ili SPC (eng. *Statistical process control*) možemo definirati kao uporabu statističkih alata i tehnika pri upravljanju i poboljšavanju procesa. [5] Točnije, svrha korištenja ovih alata je povećanje kvalitete procesa smanjenjem njegove varijabilnosti do određenih granica unutar kojih je proizvod sukladan. Glavni alat statističke kontrole procesa su kontrolne karte.

3.1.1. Kvaliteta

Pojam koji danas neizostavno vežemo uz bilo koje uspješno poduzeće, uspješan proizvod ili uslugu. Lako možemo odrediti nešto što je kvalitetno, no kako definirati riječima pojam kvaliteta? Jedna definicija je:

Kvaliteta je zadovoljenje zahtjeva kupca. [6]

Konkurentna poduzeća danas više nemaju izbor između jeftinog proizvoda i kvalitetnog proizvoda, jer kupci danas zahtijevaju kvalitetan proizvod po konkurentnim cijenama. Za poduzeće to znači da je kvaliteta nužna za opstanak poslovanja, a kontrola kvalitete je neizostavan segment proizvodnje.

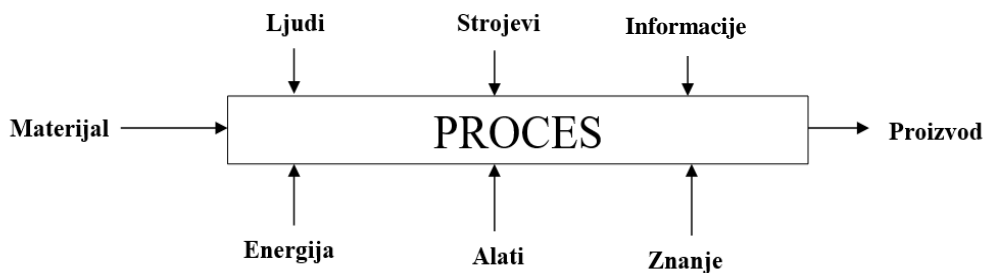
Kontrola kvalitete, odnosno implementacija iste, je također bitna jer o tome ovisi na koji način proizvodnja gleda na proces. Danas je potrebno pratiti proizvodnju i djelovati preventivno kako sukladnosti uopće ne bi ni nastale, jer jedino tako poduzeća mogu isporučiti proizvode koji zadovoljavaju zahtjeve kupca na vrijeme. Osim što kupac očekuje kvalitetan proizvod, očekuje ga i na vrijeme, pa poduzeće nema vremena kontrolirati kvalitetu proizvoda nakon završenog procesa proizvodnje, što je „stari“ način.

3.1.2. Proces

Obzirom da je u definiciji rečeno da se statistička kontrola procesa odnosi na procese, prije svega je potrebno definirati što je proces:

Proces je sve što je potrebno za pretvorbu ulaza u izlaz za kupca. [5]

Ovakva općenita definicija se može primijeniti na široki spektar industrija, od proizvodnje i zdravstva, do raznih uslužnih zanimanja. No svima je zajedničko da pretvaraju ulaze u izlaze koje su tada kupci spremni platiti. Shematski prikaz procesa proizvodnje:



Slika 4. Shematski prikaz procesa proizvodnje [5]

Shematski prikaz pokazuje kako su ulazi u neki proizvodni proces materijal od kojega se izrađuje proizvod, ljudi u vidu inženjera i operatera strojeva, strojevi kojima se vrši obrada, energija koja je potrebna za obradu, alati kojima se obrađuje materijal, vrijeme koliko proces traje i znanje kako povezati sve ove ulaze i iz njih stvoriti proizvod, odnosno izlaz procesa.

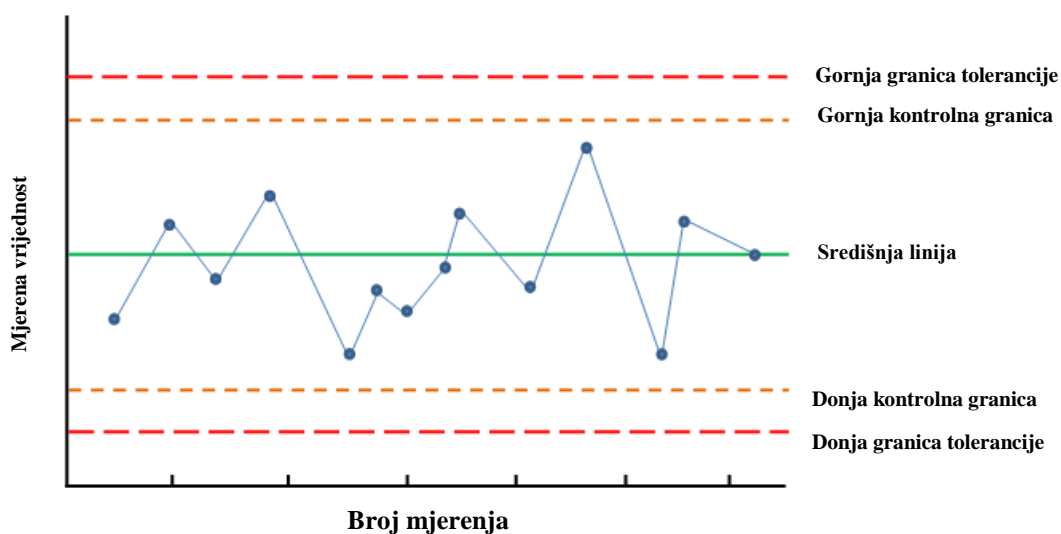
3.2. Kontrolne karte

Kako se statistička kontrola procesa koristi za dobivanje informacija i donošenje odluka u vezi procesa, osnovu za to čine skupljanje podataka i statistička obrada, a najčešći alat za prikaz podataka su kontrolne karte.

3.2.1. Značajke

Većina kontrolnih karti se sastoji od sljedećih značajki:

- Gornja i donja granica tolerancije: postavljene od strane kupca
- Gornja i donja kontrolna granica: računaju se kao $\pm 3\sigma$ promatranog parametra te nisu povezani s granicama tolerancije, već ih sam proces određuje
- Središnja linija




Slika 5. Opći izgled kontrolne karte

3.2.2. Ciljevi

Razlikujemo nekoliko ciljeva primjene kontrolnih karata u statističkoj kontroli procesa:

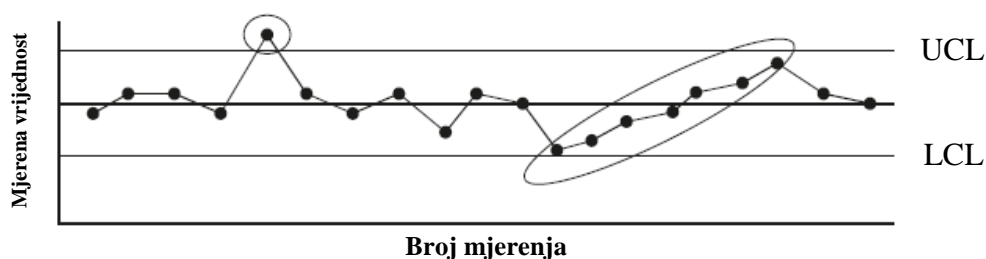
1. Dovođenje procesa u stanje statističke kontrole [7]

Svaki proizvod, pa tako i povlačni vijak, nije jednak koliko god se radilo o serijskoj proizvodnji. Svi vijci trebaju biti unutar granica tolerancija koje je postavio kupac, no od vijka do vijka će se mjere promjera i duljina mijenjati. Statistička kontrola procesa razlikuje slučajne uzroke varijacija i značajne uzroke varijacija. Kada se u procesu javljaju samo slučajni uzroci varijacija tada se kaže da je isti u stanju statističke kontrole. Tada su vrijednosti na kontrolnoj karti slučajno distribuirane oko središnje linije, unutar kontrolnih granica, i ne pojavljuju se vidljivi uzorci. Proces je tada stabilan.




Slika 6. Proces u stanju statističke kontrole [5]

S druge strane, kada se u procesu javljaju vrijednosti koje iskaču izvan kontrolnih granica ili ako pokazuju određeni uzorak, tada govorimo o značajnom uzroku varijacije. U tom slučaju je potrebno provesti određene korektivne radnje kako bi proces ponovno postao stabilan. U nastavku su navedeni neki primjeri kontrolnih karti koji ukazuju na nestabilan proces:



Slika 7. Nestabilan proces (točka izvan kontrolnih granica, trend) [5]



Slika 8. Nestabilan proces (ciklički trend, jednostranost) [5]

Uzroci slučajnih varijacija su dio samog procesa i uvijek su prisutni, pa uglavnom ne stvaraju probleme jer su predvidljivi. Uzroci značajnih varijacija nisu dio procesa te nisu predvidljivi,

pa ih je potrebno čim nastanu identificirati i ukloniti. Neki česti uzroci u proizvodnji su krivo postavljen stroj ili alat, potrošeni alat, krivo postavljen obradak, novi materijal, itd.

2. *Dobivanje saznanja o mogućnostima poboljšavanja procesa i mogućnostima postizanja zahtijevane kvalitete proizvoda (procjenjivanje sposobnosti procesa) [7]*

Nakon što je odrađen prvi cilj korištenja kontrolnih karata, odnosno nakon što su uklonjeni značajni uzroci varijacija i proces se nalazi u stanju statističke kontrole, možemo procijeniti sposobnost procesa.

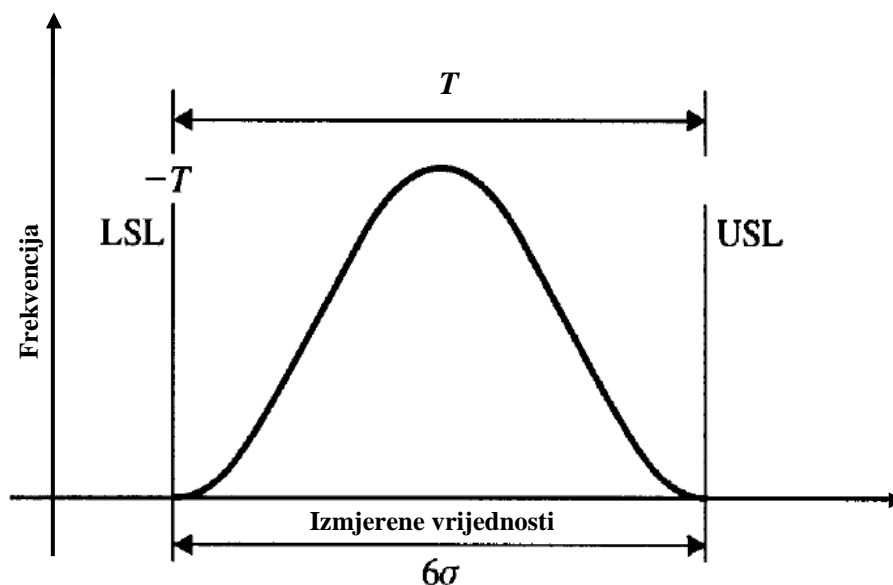
3.3. Sposobnost procesa

U stanju statističke kontrole procesa moguće je utvrditi koliko iznosi varijabilnost procesa uslijed slučajnih uzroka varijacija. Varijabilnost procesa se označava u standardnim devijacijama, odnosno najčešće se uzima u obzir područje od 6σ ispod razdiobe procesa. Iz toga proizlazi da je osnovni zahtjev na proces:

$$T > 6\sigma \quad (1)$$


$$T = USL - LSL \quad (2)$$

Gdje su T = tolerancijski raspon, USL = gornja granica tolerancije, LSL = donja granica tolerancije



Slika 9. Sposobnost procesa [6]

Obzirom na odnos varijabilnosti procesa i tolerancijskog polja, možemo podijeliti procese na one visoke kvalitete (preciznosti), srednje kvalitete i niske kvalitete.




Slika 10. Procesni niski, srednji i visoki kvalitete [6]

- Proces visoke kvalitete (slika 10.a): tolerancijsko polje je znatno šire od varijabilnosti procesa (6σ)
- Proces srednje kvalitete (slika 10.b): tolerancijsko polje je otprilike širine varijabilnosti procesa (6σ)
- Proces niske kvalitete (slika 10.c): tolerancijsko polje je uže od širine varijabilnosti procesa (6σ), proces proizvodi nesukladne komade

3.3.1. Indeksi sposobnosti procesa

Sposobnost procesa se može prikazati grafički, kako je prethodno pokazano ili numerički pomoću indeksa sposobnosti procesa. Opći uvjet sposobnosti procesa govori kako je potrebno da su tri standardne devijacije procesa sa svake strane očekivane vrijednosti procesa unutar

tolerancijskog polja. Tada se može reći da će otprilike 99.73% proizvoda biti unutar traženih tolerancija.



Slika 11. Površina tri standardne devijacije od očekivane vrijednosti [10]

3.3.1.1. C_p – Potencijalna sposobnost procesa

Kako bi proizvodi bili sukladni traženim specifikacijama, očito je da je potrebno da ukupna varijabilnost procesa bude manja od razlike gornje tolerancijske granice i donje tolerancijske granice. Indeks C_p nam pokazuje odnos tolerancijskog polja i ukupne varijabilnosti procesa, a računa se kao:

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

Ako je vrijednost indeksa C_p manja od 1, onda se može zaključiti kako je varijabilnost procesa veća od tolerancijskog polja. Proces nije sposoban i potrebno je smanjiti varijabilnost kako bi mogao proizvoditi sukladne komade. Stoga, veća vrijednost C_p znači i sposobniji proces. Ovaj indeks ne govori o centriranosti procesa u odnosu na tolerancijsko polje već samo govori o odnosu varijabilnosti i tolerancijskog polja.


Preporučene vrijednosti indeksa C_p su:

Tablica 4. Preporučene vrijednosti C_p [16]

<i>Vrsta procesa:</i>	Preporučeni minimalni C_p za dvostrano specificiranu karakteristiku	Preporučeni minimalni C_p za jednostrano specificiranu karakteristiku
<i>Postojeći proces:</i>	1,33	1,25
<i>Novi proces:</i>	1,50	1,45
<i>Sigurnosna ili kritična karakteristika postojećeg procesa:</i>	1,50	1,45
<i>Sigurnosna ili kritična karakteristika novog procesa:</i>	1,67	1,60
<i>Six-sigma proces:</i>	2,00	2,00

3.3.1.2. C_{pk} – Demonstrirana izvrsnost

Obzirom da indeks C_p ne govori o centriranosti procesa već samo o njegovoj potencijalnoj sposobnosti, potreban je još jedan indeks koji u obzir uzima i položaj procesa u tolerancijskom polju.



Slika 12. Proces izvan centra [6]

Na slici 12. moguće je vidjeti primjer procesa koji bi bio sposoban da se nalazi u centru tolerancijskog polja, jer nema veliku varijabilnost, no zbog toga što se nalazi izvan centra određeni dio proizvoda će biti izvan tolerancije.

Za svaku granicu tolerancije postoji C_{pk} vrijednost – C_{pl} i C_{pu} . C_{pk} procesa je tada manja vrijednost od izračunatog C_{pl} i C_{pu} . Vrijednosti indeksa C_{pl} i C_{pu} se računaju kao:

$$C_{pu} = \frac{USL - \bar{X}}{3\sigma} \quad (4)$$

$$C_{pl} = \frac{\bar{X} - LSL}{3\sigma} \quad (5)$$

$$C_{pk} = \min(C_{pu}, C_{pl}) \quad (6)$$

C_{pu} i C_{pl} indeksi govore o odnosu razlike gornje i donje granice tolerancije sa sredinom procesa i polovicom varijacije procesa. Kao što je slučaj s indeksom C_p , iznos C_{pk} manji od 1 nam govori o procesu koji nije sposoban, odnosno da će proces biti izvan gornje ili donje granice tolerancija. U slučaju centriranosti procesa, iznosi indeksa C_p i C_{pk} će biti jednaki.

4. SPOSOBNOST POSTOJEĆEG PROCESA

Sposobnost postojećeg automatiziranog proizvodnog procesa opisanog u točki 2 može se analizirati pomoću izraza iz točke 3. Analiza se vrši na uzorku od 100 vijaka koristeći vrijednosti dimenzije jednog od obrađivanih promjera vijka.

4.1. Karakteristike dimenzije i uzorka

Podaci o mjerenoj karakteristici su u sljedećoj tablici:

Tablica 5. Karakteristike dimenzije za analizu procesa

<i>n</i> :	100
<i>Nominalna vrijednost</i> :	Ø26,06 h7 mm
<i>USL</i> :	26,060 mm
<i>LSL</i> :	26,039 mm
<i>Srednja vrijednost</i> :	26,050 mm
<i>T</i> :	0,021 mm


Kako se radi o relativno uskom tolerancijskom polju, podaci su dobiveni mjerenjem vijaka na digitalnom mikrometru s rezolucijom od 0,001 mm. Deskriptivna statistika uzorka se nalazi u sljedećoj tablici:

Tablica 6 Deskriptivna statistika uzorka

\bar{x} :	26,050 mm
<i>Medijan</i> :	26,050 mm
<i>Mod</i> :	26,051 mm
<i>Min</i> :	26,047 mm
<i>Max</i> :	26,054 mm
<i>R</i> :	0,008 mm
σ :	0,0017 mm
σ^2 :	0,000003
α_3 :	0,1924

Iz tablice 5 se može zaključiti kako je proces vrlo centraliziran, jer mjere centralne tendencije aritmetička sredina i medijan poprimaju srednje vrijednosti tolerancijskog polja, dok mod poprima za jedan veću vrijednost. Mjere varijabilnosti govore da je proces precizan, obzirom

da je već raspon gotovo dvostruko manji od tolerancijskog polja, a standardna devijacija je također niska. Koeficijent asimetrije je manji od 0,25 što pokazuje zanemarivu asimetriju procesa.



Slika 13. Histogram procesa na postojećem radnom mjestu

Histogram na slici 13 pokazuje frekvencije podataka u 6 razreda. Ucertane su i gornja i donja granica tolerancije (USL i LSL) te gornja i donja kontrolna granica koja je računata prema izrazu:

$$UCL, LCL = \bar{x} \pm 3 \cdot \sigma \quad (7)$$

$$UCL = 26,055 \text{ mm}$$

$$LCL = 26,045 \text{ mm}$$

Iz histograma je vidljivo da se kontrolne granice procesa nalaze unutar tolerancijskog polja mjerene dimenzije. Osim toga, može se uočiti i da se sve mjerene vrijednosti nalaze unutar kontrolnih granica. Na slici je također preko histograma preklapljen graf normalne razdiobe

koji prikazuje rasipanje procesa. Može se zaključiti da se radi o procesu visoke kvalitete, prema usporedbi s procesima sa slike 10.

4.2. Indeksi sposobnosti procesa analiziranog uzorka

Nakon vizualne predodžbe stanja procesa pomoću histograma i grafa normalne razdiobe, računaju se i pokazatelji sposobnosti procesa pomoću izraza iz točke 3.

4.2.1. Osnovni uvjet sposobnosti procesa

Prema izrazu 1 točke 3.3 osnovni uvjet koji svaki sposobni proces mora zadovoljiti je da njegova varijabilnost izražena kao $\pm 3\sigma$ mora biti manja od raspona tolerancijskog polja. Iz izraza s vrijednostima iz tablice 4 i izraza 7 dobiva se:

$$0,021 > 0,0103 \quad (8)$$

Kako je tolerancijsko polje veće od $\pm 3\sigma$, zaključeno je da proces zadovoljava osnovni uvjet sposobnosti procesa.

4.2.2. Potencijalna sposobnost procesa

Indeks C_p predstavlja potencijalnu sposobnost procesa koja govori o odnosu varijabilnosti procesa i tolerancijskog polja. Računa se prema izrazu 3 i pomoću vrijednosti iz tablice 4 i izraza 7 i iznosi:

$$C_p = \frac{0,021}{0,0103} = 2,04 \quad (9)$$

Prema tablici 5 može se zaključiti kako promatrani proces zadovoljava minimalni iznos indeksa potencijalne sposobnosti za postojeći proces s dvostrano specificiranom karakteristikom. Točnije, analizirani uzorak je pokazao čak Six-Sigma razinu procesa.

4.2.3. Demonstrirana izvrsnost

Kako indeks C_p ne uzima u obzir položaj procesa u tolerancijskom polju računa se indeks C_{pk} koji pokazuje centriranost procesa. Prema izrazima 4, 5 i 6 i pomoću podataka iz tablice 6 i izraza 7 demonstrirana izvrsnost procesa iznosi:

$$C_{pu} = \frac{26,060 - 26,050}{0,005} = 2 \quad (10)$$


$$C_{pl} = \frac{26,050 - 26,039}{0,005} = 2,2 \quad (11)$$

$$C_{pk} = 2 \quad (12)$$

Vrijednosti indeksa demonstrirane izvrsnosti su veće od 1 za obje granice tolerancija što ukazuje da je proces sposoban. Kako je vrijednost C_{pu} manja od vrijednosti C_{pl} vidljivo je da proces nije centriran te da je pomaknut u desno u odnosu na sredinu tolerancijskog polja.

4.3. Dodatni histogram i demonstrirana izvrsnost

U točkama 4.1 i 4.2 pokazan je histogram i izračunati indeksi sposobnosti procesa koristeći jednu od dimenzija vijka u uzorku, a u nastavku će biti prikazan histogram i demonstrirana izvrsnost još jednog promjera na vijcima u uzorku kako bi se dodatno utvrdila visoka preciznost i točnost promatranog procesa.



Slika 14. Histogram procesa prikazan pomoću druge dimenzije

Na slici 14 je također vidljivo da se radi o vrlo preciznom i točnom procesu obzirom da sami raspon izmjerenih vrijednosti iznosi 0,01 mm dok tolerancijsko polje mjerene dimenzije iznosi $\pm 0,127$ mm. Iznos demonstrirane izvrsnosti je:

$$C_{pu} = \frac{29,083 - 28,951}{0,006} = 22$$

$$C_{pu} = \frac{28,951 - 28,829}{0,006} = 20,33$$

$$C_{pk} = 20,33$$


Ovako veliki iznosi indeksa demonstrirane izvrsnosti proizlaze iz činjenice što drugi analizirani promjer ima puno veće tolerancijsko polje od promjera u točki 4.1.

5. AUTOMATSKA KONTROLA DIMENZIJA I AKVIZICIJA PODATAKA

U prethodnim poglavljima je zaključeno kako postoji prostora za unaprjeđenje i daljnju automatizaciju radnog mjesta, a to će se ostvariti automatskom kontrolom dimenzija proizvoda uz automatsku akviziciju podataka mjerenja. U nastavku se opisuju moguća rješenja i zahtjevi istih.

5.1. Odabir dimenzije

Prvenstveno treba utvrditi koje će se dimenzije automatski mjeriti u predloženom rješenju. Kako je opisano u točki 2.2 trenutno se proces kontrole kvalitete sastoji u tome da operater na izuzetom vijku mjeri četiri različite značajke koje su prikazane u sljedećoj slici:



Slika 15. Obradene površine vijka

Crvenom bojom su označene obrađene površine i njihove dimenzije. Vijak na slici 13 je samo jedan od različitih vijaka koji se obrađuju, no uglavnom se obrađuju gore označene površine i na drugim vijcima. Stoga, moguće je utvrditi da se radi o dva promjera (na slici 13 D_2 i D_3) i o dvije duljinske dimenzije (na slici L_2 i L_3). Trenutno se za kontrolu kvalitete odnosno mjerenje navedenih značajki koriste dva mikrometra i visinomjer. Obzirom na kompleksnost mjernog postupka za primjenu automatiziranog rješenja pokušat će se pojednostaviti proces mjerenja tako da se mjeri samo jedna značajka vijka i na taj način da se utvrdi sukladnost vijka.

Odabire se promjer D_2 iz nekoliko razloga:

- Najuže tolerancijsko polje od obrađivanih površina
- Svi vijci u proizvodnji se mogu klasificirati u dvije skupine ovisno o veličini tog promjera što pojednostavljuje automatiziranje mjerenja
- Promjer je lakše mjeriti od duljinskih dimenzija vijka

Pošto je mjerenje četiri različite dimenzije zamijenjeno jednom odabranom dimenzijom, potrebno je obrazložiti takvu odluku, odnosno na koji način se ostale dimenzije odnose na dobiveni iznos dimenzije odabrane dimenzije.

5.2. Povezanost dimenzija

Kako bi se što točnije mogla određivati sukladnost vijka pomoću mjerenja samo jedne njegove dimenzije, potrebno je postaviti proces obrade na način da su mjerene površine u što većoj međusobnoj povezanosti. Drugim riječima, obzirom da radi o relativno jednostavnom procesu obrade, postavljen je zahtjev da se sve mjerene površine obrađuju samo jednim alatom i da se trošenje alata korigira pomoću samo jedne korektivne vrijednosti. Trenutno se proces ne izvodi na opisani način već se ovisno o vrsti vijka koriste jedan do dva alata za mjerene površine (čak i kada je moguće izvršiti proces jednim alatom), te dvije korektivne vrijednosti. Naravno, na taj način je jednostavnije upravljati procesom i trošenjem alata kada čovjek izvodi kontrolu kvalitete, no isto tako se zahtijeva i veći broj intervencija operatera.

Tablica 7. Stanje obrade prije i poslije promjene procesa

	Stanje obrade prije:	Stanje obrade poslije:
<i>Broj alata:</i>	1 - 2	1
<i>Broj korektivnih vrijednosti:</i>	2	1

Zahtijevana promjena procesa na radnom mjestu je napravljena, a u nastavku su objašnjene povezanosti pojedinih dimenzija s odabranom dimenzijom za mjerenje:

5.2.1. Odnos dimenzije D_2 i D_3


Dimenzije D_2 koja će se mjeriti i dimenzija D_3 su promjeri. Kako će se sve mjerene dimenzije obrađivati jednim alatom za pretpostaviti je da će ti promjeri biti u određenoj vezi, odnosno korelaciji. Stoga je potrebno napraviti korelacijsku analizu ove dvije varijable (D_2 i D_3) kako bi se numerički utvrdila jačina njihove povezanosti, odnosno koeficijent korelacije. Analiza je izvršena na uzorku jedne vrste vijaka nakon što su uvedene zahtijevane promjene

procesa obrade. Podaci o iznosima dimenzija D_2 i D_3 su dobiveni mjerenjem pomoću mikrometra s rezolucijom od 0,001 mm. U nastavku su pokazani rezultati korelacijske analize:

Tablica 8. Korelacijska analiza dimenzija D_2 i D_3


Vrsta vijka:	Povlačni vijak 1“-8 CAT
n	112
Tolerancija D_2 :	Ø26,06 h7 (-0,021)
Tolerancija D_3 :	Ø28,956 ± 0,127
\bar{x}_{D_2} :	26,051
\bar{x}_{D_3} :	28,951
σ_{D_2} :	0,00024
σ_{D_3} :	0,00261
r	0,83
r^2	0,69
α	0,05
p	$4,92 \cdot 10^{-30}$

Koeficijent korelacije iznosi 0,83 što označava vrlo dobru povezanost ova dva promjera, a koeficijent determinacije koji iznosi 0,69 govori da se 69% promjene promjera D_3 može objasniti promjenom promjera D_2 . Nadalje, izračunata je p-vrijednost skupa podataka kojim se utvrđuje značajnost koeficijenta korelacije. Hipoteza H_0 tvrdi da je koeficijent korelacije osnovnog skupa jednak 0, a hipoteza H_1 tvrdi da koeficijent korelacije nije jednak nula. Izračunata p vrijednost iznosi $4,92 \cdot 10^{-30}$ što je manje od razine značajnosti od 0,05 pa se stoga prihvaća hipoteza H_1 što znači da postoji statistički značajna korelacija između promjera D_2 i D_3 .



Slika 16. Dijagram rasipanja D_2 i D_3

Analiza i vizualizacija su izvršeni pomoću programa Microsoft Excel. Na slici 16 je prikazan dijagram rasipanja izmjerenih vrijednosti varijabli D_2 i D_3 . Osim točaka rasipanja na dijagramu je prikazan i pravac regresije s granicama pouzdanosti uz pouzdanost 95 %.



Slika 17. Kretanje vrijednosti D_2 i D_3 u uzorku

Još jedna vizualizacija koja pokazuje da se radi o vrlo dobroj korelaciji nalazi se na slici 15. Ovdje se može vidjeti kretanje vrijednosti svake varijable zasebno, a kako se nalaze jedna iznad druge očita je povezanost kretanja istih.


Provedenom korelacijskom analizom promjera D_2 i D_3 moguće je zaključiti kako su te varijable vrlo dobro povezane. To je u skladu s pretpostavkom jer se oba promjera obrađuju istim alatom i korigiraju se istom korektivnom vrijednosti. Stoga i trošenje alata i korekcije utječu i na jedan i na drugi promjer istovremeno. Kako će se automatiziranjem kontrole dimenzija mjeriti samo promjer D_2 , bitno je bilo utvrditi da je na taj način moguće pouzdano odrediti i sukladnost promjera D_3 .

5.2.2. Odnos dimenzije D_2 i dimenzija L_2 i L_3

Dvije duljinske dimenzije L_2 i L_3 koje se mjere pomoću visinomjera imaju znatno veće tolerancijsko polje od promjera D_2 i D_3 . U primjeru vijka pomoću kojeg je izvršena korelacijska analiza promjer D_2 ima tolerancijsko polje koje iznosi $0,02mm$, dok mjere L_2 i L_3 imaju tolerancijska polja veličine $0,25mm$ što je za red veličine veće polje. Stoga se uvodi razumna pretpostavka da će dimenzije L_2 i L_3 biti sukladne ukoliko je mjerena dimenzija L_2 koja mora biti red veličine preciznija sukladna.

5.3. Odabir kontrolne karte

Obzirom da je primjena kontrolne karte osnova statističke kontrole procesa, prvo je potrebno odabrati vrstu kontrolne karte koja će odgovarati procesu proizvodnje povlačnih vijaka. Na slici 18 je prikazan dijagram tijeka za odlučivanje o vrsti kontrolne karte.



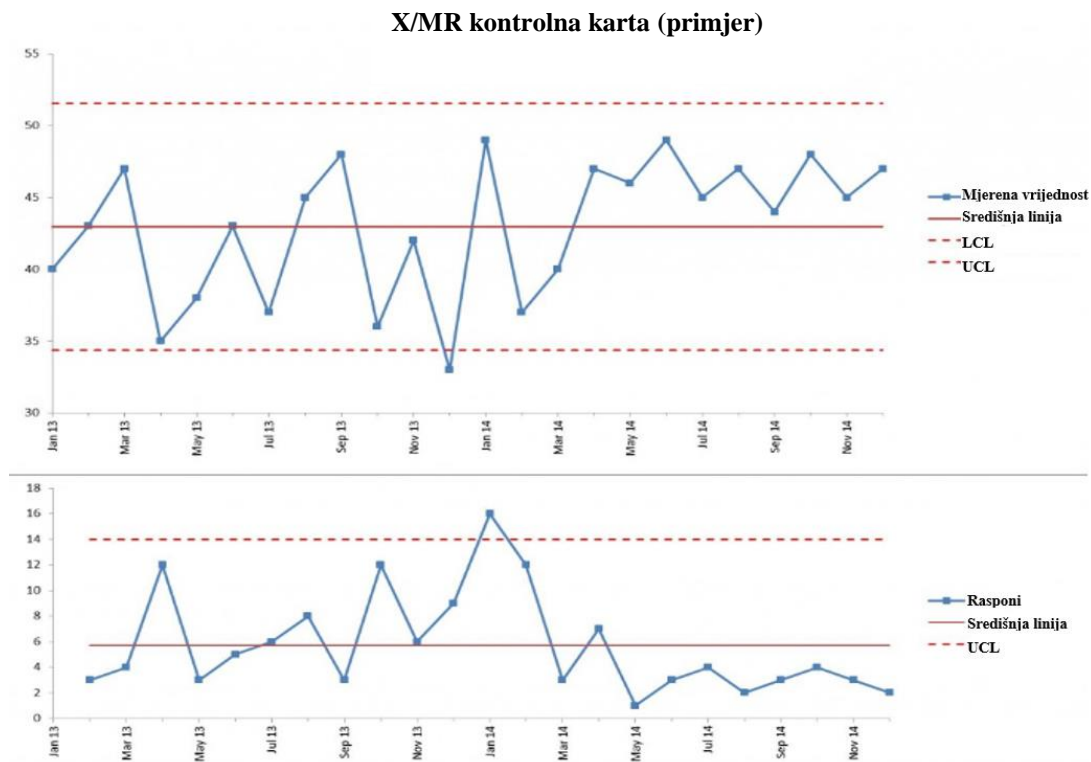
Slika 18. Odabir kontrolne karte [5]

Prvo pitanje koje se postavlja pri odabiru kontrolne karte je koja vrsta podataka u procesu će se bilježiti. Osnovna podjela je na podatke s mjerljivim karakteristikama ili one s atributivnim karakteristikama. Mjerljive karakteristike su one čije podatke prikupljamo mjerenjem, a neki primjeri su duljina, težina, vrijeme, volumen, itd. Ovi podaci se još nazivaju i kontinuirani podaci. Atributivne karakteristike su one koje opisuju ima li predmet određeni atribut ili nema, a neki primjeri su broj žalbi, reklamacija, grešaka, nesukladnih jedinica, itd. Ovi podaci se još nazivaju i diskretni podaci. Obzirom da se u procesu proizvodnje vijaka prate karakteristike kao što su promjeri i duljine, odabiru se mjerljive karakteristike kao vrsta podataka u dijagramu tijeka.

Sljedeće pitanje se odnosi na veličinu uzorka iz kojeg će se dobivati potrebni podaci o procesu. Točnije, radi li se o uzorcima kojeg čini samo jedan proizvod u uzorku ili više njih. U promatranom slučaju uzorak će činiti samo jedan vijak, odnosno vrijednost njegove dimenzije D2. Odabirom ove veličine uzorka dijagram tijeka govori kako je potrebno izabrati X/MR kontrolnu kartu.

5.4. Postavljanje kontrolne karte

Odabrana je X/MR kontrolna karta koja se još naziva i individualna karta jer se uzimaju uzorci od samo jednog proizvoda, a ne grupe proizvoda. Zbog svoje prirode ova vrsta kontrolne karte ima široku primjenu i vrlo je jednostavna za postavljanje. Kontrolna karta se sastoji od X i MR karte koje se uglavnom crtaju zajedno, jedna iznad druge.



Slika 19. Primjer X/MR kontrolne karte

Kako proces bude tekao tako će se automatski računati vrijednosti središnje linije procesa i kontrolnih granica. Što više vrijednosti u procesu bude izmjereno, to će kontrolne granice biti točnije.. Izmjerene vrijednosti dimenzije D2 će se ucrtavati na X/MR karte. U promatranom slučaju mjerit će se svaki vijak, a po potrebi će se učestalost mijenjati. Nakon što se dobiju vrijednosti mjerenja promatranih karakteristika, potrebno je računati i njihove kretajuće raspone prema izrazu:

$$MR_i = x_i - x_{i-1} \quad (13)$$

Gdje su MR_i = i-ti kretajući raspon, x_i = i-ta vrijednost mjerenja. Po završetku mjerenja računa se aritmetička sredina svih individualnih mjerenja prema izrazu:

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n} \quad (14)$$

Gdje su \bar{x} = aritmetička sredina vrijednosti mjerenja, n = broj mjerenja. Na isti način se računa i aritmetička sredina kretajućih raspona:

$$\bar{R} = \sum_{i=1}^n \frac{MR_i}{n} \quad (15)$$

Gdje je \bar{R} = aritmetička sredina kretajućih raspona. S prethodno dobivenim podacima može se izračunati standardna devijacija prema izrazu:

$$S_{MR} = \frac{\bar{R}}{1,128} \quad (16)$$

Gdje je S_{MR} = standardna devijacija prema kretajućim rasponima, a broj 1.128 je Hartley-eva konstanta koja se koristi za izračunavanje standardne devijacije iz aritmetičke sredine kretajućih raspona. Gornja i donja kontrolna granica za X kartu se tada računaju prema izrazu:

$$UCL_X, LCL_X = \bar{x} \pm 3 \cdot S_{MR} \quad (17)$$

Gdje su UCL_X i LCL_X = gornja i donja kontrolna granica X karte. MR karta ima samo gornju kontrolnu granicu koja se računa prema izrazu:

$$UCL_{MR} = 3,27 \cdot \bar{R} \quad (18)$$

5.5. Kontrola pomoću postojeće mjerne sonde

Na CNC tokarskom stroju kojim se obavlja obrada tvrdog tokarenja postavljena je mjerna sonda proizvođača Marposs, model VOP40L. Ova sonda se koristi iz razloga što se povlačni vijci obrađuju između okretnih šiljaka, pa samim nalijeganjem vijaka na šiljke postoje varijacije u njihovoj poziciji u prostoru. Stoga navedena sonda na početku procesa obrade utvrđuje položaj vijka, odnosno njegovu nul-točku, a nakon toga tek započinje odvajanje čestica. Specifikacije mjerne sonde su sljedeće (određene značajke ovise o vrsti sonde):

Tablica 9. Značajke VOP40L

<i>Ponovljivost (jedan smjer)</i>	0,0005 ili 0,001 mm
<i>Sila aktivacije:</i>	0,5 do 0,9N, 2N (XY ravnina) 5,8N, 12N (Z os)
<i>Način prijenosa podataka:</i>	Optički prijenos

Kada sonda dotakne vijak na određenom njegovom dijelu, stroj očita pozicije svojih enkodera i zapiše ih u određene strojne varijable koje se tada koriste dalje u programu. Na ovom principu je zasnovano ovo predloženo rješenje

Ovo rješenje automatizacije kontrole dimenzija i akvizicije podataka sastoji se od sljedećih dijelova:

- Mjerna sonda Marposs VOP40L koja se nalazi na stroju
- Potprogram za mjerenje vijka pomoću sonde nakon obrade
- Vanjsko računalo koje prima podatke i obrađuje ih u programu
- Monitor za prikaz SPC podataka i interakciju

U nastavku su pobliže opisuju pojedine komponente ovog rješenja.

5.5.1. Mjerna sonda Marposs VOP40L

Već spomenuta mjerna sonda koje se i trenutno nalazi na stroju koristit će se za dobivanje podataka o X i Z poziciji prilikom mjerenja dimenzije D_2 . Sonda je postavljena na jednu od pozicija revolvera stroja i orijentirana je u radijalnom smjeru. Kako se sonda već koristi u procesu obrade njeno korištenje za mjerenje dimenzija ne bi iziskivalo dodatna ulaganja u opremu, već bi se koristila postojeća. U postojeći proces bi se na kraju dodao potprogram za mjerenje tijekom kojeg bi se sonda pozicionirala iznad površine vijka gdje se nalazi dimenzija D_2 te bi izmjerila njenu vrijednost, nakon čega bi se vratila u početni položaj i time bi završio ciklus obrade. Nedostatak korištenja postojeće sonde na ovakav način je što se time produljuje postojeći proces obrade.



Slika 20. Mjerna sonda Marposs VOP40L

5.5.2. Potprogram za mjerenje

Mozak cijele operacije je potprogram za mjerenje kojim se obavljaju potrebna gibanja, mjerenje, odlučivanje, spremanje i slanje podataka. Potprogram je jednostavan i sadrži standardne naredbe G-koda kojima se opisuje gibanja alata. Kada sonda dotakne vijak na

površini dimenzije D_2 tada upravljačko računalo stroja očita pozicije svojih enkodera i spremi ih kao makro varijable definirane u potprogramu. Nakon toga se u potprogramu dalje izvršavaju naredbe s uvjetima. Moguće je programirati da ako je izmjerena vrijednost unutar određenih kontrolnih granica da se proces normalno dalje nastavlja, a ukoliko je izvan da se čitavi proces zaustavi dok ga operater ponovno ne pokrene. Osim za odlučivanje u uvjetima, očitana vrijednost bi također bila poslana na vanjsko računalo za program koji bi podatke koristio za SPC u realnom vremenu. Primjer dijelova takvog potprograma:

T8;	Pozivanje mjerne sonde
...	
#100 = 29;	X koordinata dimenzije D2
#101 = -5;	Z koordinata dimenzije D2
#102 = -0,02;	Gornja granica tolerancije
#103 = -0,04;	Donja granica tolerancije
...	
G0 Z#101;	Brzi hod do Z koordinate dimenzije D2
...	
#125 = #100-1;	Pomoćna varijabla
G31 X[#100] F1000;	Gibanje do koordinate u varijabli 100 uz traženje signala sa sonde
G31 U-2 F50;	Gibanje 2 milimetra u negativnom smjeru osi X uz traženje signala sa sonde
IF [#125 EQ #5041] GOTO20;	Uvjet ako je trenutna vrijednost X osi jednaka pomoćnoj varijabli 125 idi na liniju 20
#150 = #5041;	Spremanje trenutne vrijednosti X osi u varijablu 150
...	
#160 = [#100+#102];	Apsolutni iznos gornje granice tolerancije
#161 = [#100+#103];	Apsolutni iznos donje granice tolerancije
IF[#150 GT #160] GOTO99;	Uvjet ako je spremljena vrijednost u varijabli 150 veća od varijable 160, idi na liniju 99
IF[#150 LT #161] GOTO99;	Uvjet ako je spremljena vrijednost u varijabli 150 manja od varijable 160, idi na liniju 99
POPEN;	Početak komunikacije
DPRNT[#150];	Slanje varijable 150 na vanjsko računalo
PCLOS;	Završetak komunikacije
...	
M99;	Kraj potprograma
N20;	Linija 20
#3000 = 1;	Greška, sonda nije dotakla vijak
N99;	Linija 99
#3000 = 1;	Greška, mjerena vrijednost je izvan tolerancija

Slika 21. Primjer potprograma za automatsko mjerenje vijaka

Prikazani su samo određeni dijelovi jednog takvog potprograma koji bi se koristio za automatsko mjerenje i dobivanje mjernih rezultata. Potprogram je razvijen uz pomoć vanjske tvrtke koja nudi usluge postavljanja komponenti na stroj. Od operatera bi se zahtijevalo samo unošenje vrijednosti varijabli o X i Z poziciji mjerne površine, odnosno dimenzije D_2 i granice tolerancije koje programu služe za provjeravanje uvjeta. U slučaju da je mjera D_2 izvan određenih granica, naredba #3000 zaustavlja stroj i čitavi proces. Ako je vrijednost D_2 unutar granica, započinje se komunikacija s vanjskim računalom preko RS232 protokola.

5.5.3. Vanjsko računalo i monitor

Vanjsko računalo koje se koristi u ovom rješenju mora imati mogućnost povezivanja s RS232 izlazom iz obradnog stroja, mogućnost ostvarivanja komunikacije i preuzimanja podataka koje je spremio potprogram i mogućnost pokretanja programa za statističku kontrolu procesa koji je opisan dalje u radu. Uz računalo se nalazi i monitor na kojem se prikazuju relevantni SPC podaci i koji omogućuje interakciju računala s operaterom.

5.6. Kontrola izvan stroja

Rješenje koje je prvo opisano podrazumijeva automatsko mjerenje na samom stroju pomoću postojeće opreme. Iako su na taj način smanjeni troškovi implementacije takvog rješenja, takvim rješenjem se produžuje proces obrade vijka za duljinu trajanja izvođenja dodatnog potprograma za mjerenje. Prednosti ovakvog rješenja još uvijek su veće od nedostataka jer kako je već rečeno u prethodnom radu još uvijek nije popunjen kapacitet robota, odnosno radnog mjesta. No za očekivati je povećanje obujma posla, a s time je potrebno razmišljati i o alternativnim rješenjima automatske kontrole kvalitete, koja neće produljivati proces obrade. S time na umu u nastavku se razmatra alternativno rješenje procesa automatskog mjerenja koje se odvija izvan stroja i izvan procesa obrade.

U točki 2.1 opisano je postojeće rješenje za automatizaciju posluživanja stroja koje se sastoji od robotske ćelije unutar koje se nalazi paletni spremnik i robot. Opisan je i proces izmjene vijka gdje treba dodati da nakon što završi ciklus izmjene robot čeka završetak obrade kako bi ponovno započeo novi ciklus izmjene. Ovim rješenjem se želi upravo to vrijeme iskoristiti za proces automatske kontrole dimenzija. Stoga su dijelovi predloženog rješenja za mjerenje izvan stroja:

- Robot ABB IRB 1200 koji se već koristi u procesu izmjene
- Naprava za mjerenje vijaka
- Sustav za mjerenje
- Potprogram robota za postavljanje vijaka u napravu
- Vanjsko računalo koje prima podatke i obrađuje ih u programu
- Monitor za prikaz SPC podataka i interakciju

5.6.1. Robot ABB IRB 1200

Industrijski robot ABB IRB 1200 se na radnom mjestu već koristi za posluživanje stroja. Pri automatskoj kontroli dimenzija robot se može koristiti za postavljanje vijaka nakon obrade u odgovarajuću napravu gdje će se izvršiti mjerenje i potom ga staviti u paletni spremnik. Robot pri završetku procesa izmjene trenutno ima određeno vrijeme gdje čeka završetak obrade na

stroju, pa je bitno da se proces mjerenja izvrši u tom vremenskom okviru kako se ne bi produljivao ciklus. Specifikacije robota su:


Tablica 10. Specifikacije ABB IRB 1200 [12]

Broj osi:	6
Nosivost:	5 kg
Najveći doseg:	900 mm
Ponovljivost:	$\pm 0,025$ mm
Masa:	54 kg
Upravljanje:	IRC5 Compact

5.6.2. Naprava za mjerenje vijaka


Ova komponenta rješenja nije bila potrebna u predloženom rješenju iz točke 4.3 jer je mjerenje bilo izvršeno u samoj steznoj napravi stroja. Za mjerenje izvan stroja je stoga potrebna naprava u koju će robot postaviti vijak po završetku obrade. Vijci se mogu klasificirati u dvije grupe ovisno o promjeru D_2 , pa su prema tome potrebne dvije naprave, svaka za jednu grupu vijaka. Pri konstruiranju takvih naprava potrebno je zadovoljiti sljedeće zahtjeve:

- Naprava mora omogućavati dovoljno dobru ponovljivost pozicioniranja
- Potreban je provrt za postavljanje mjerne sonde
- Gibanja robota za postavljanje vijaka u napravi treba biti što jednostavnije




Slika 22. Naprava za mjerenje konusa držača alata [15]

Predložena naprava na razvijena je prema uzoru na sličan uređaj koji poduzeće već koristi za kontrolu kvalitete nakon operacije brušenja držača alata. Uređaj se sastoji od naprave s analognim mjernim satovima. S tim uređajem je moguće mjeriti promjer obrušenog konusa držača alata na način da se obrađeni komad postavi u napravu gdje naliže na tvrdometalne vrhove koji ga točno pozicioniraju te se očitaju vrijednosti s mjernih satova. Ovaj koncept je primijenjen za konstrukciju predložene naprave.




Slika 23. Vizualizacija naprave za mjerenje vijaka

Na slici 17 prikazana je vizualizacija naprave za mjerenje vijaka. Naprava se postavlja na aluminijski okvir robotske ćelije i učvršćuje se pomoću dva vijka sa svake strane. U polukružni otvor naprave robot postavlja vijak, a na vrhu se nalazi provrt za mjernu sondu koja mjeri dimenziju D_2 . Robot dovodi vijak do naprave te ga naslanja na gornju ravnu plohu, dok cilindrični dio vijka gdje se nalazi dimenzija D_2 ostvaruje točkasti dodir s tvrdometalnim vrhovima koji pomažu u pozicioniranju. Naravno, ostvaruje i dodir s mjernom sondom koja očitava vrijednost promjera. Očitana vrijednost se zatim šalje na vanjsko računalo gdje se obrađuje, sprema i prikazuje.



Slika 24. Komponente naprave za mjerenje

Prikaz presjeka pokazuje trenutak mjerenja na napravi, kada robot dovede obrađeni vijak u predloženu napravu i kada se ostvari kontakt između mjerne sonde i D_2 promjera vijka. Mjerna sonda služi za mjerenje razlike između referentnog vijka i vijka koji se trenutno mjeri.



Slika 25. Dodir mjerne sonde i vijka

5.6.3. Sustav za mjerenje

Kako se u ovom slučaju mjerenje ostvaruje izvan stroja u napravi, potreban je i drugačiji sustav za mjerenje. Taj sustav mora biti u mogućnosti pružiti sondu koja se može postaviti u napravu za mjerenje i koja može obavljati proces mjerenja. Isto tako sustav treba biti u mogućnosti dobivene podatke poslati na vanjsko računalo na daljnju obradu. Poduzeće već koristi određenu opremu proizvođača Mahr za druga radna mjesta, pa se za ovu primjenu također predlaže oprema tog proizvođača.

5.6.3.1. Mjerna sonda

Predlaže se mjerna sonda Millimar P2004. Ova induktivna linearna mjerna sonda zadovoljava zahtjevima za primjenu, a u nastavku su prikazane njene karakteristike:

Tablica 11. Karakteristike mjerne sonde [13]

Mjerno područje:	$\pm 2 \text{ mm}$
Mjerna sila:	$0,75 \text{ N} \pm 0,15 \text{ N}$
Ponovljivost:	$0,1 \mu\text{m}$
Histereza:	$0,5 \mu\text{m}$
Temperaturni koeficijent	$0,15 \mu\text{m}/^\circ\text{C}$

Vrh sonde je postavljen na vodilice s kugličnim ležajevima, otporna je na elektromagnetske utjecaje i ulje, vodu, benzin i slično.

5.6.3.2. Modularno sučelje

Sondu nije moguće koristiti samu već je potreban dodatni element sustava koji će primiti, obraditi i poslati dalje signal sa sonde. Taj element je modularno sučelje Millimar N 1700 koje se sastoji od modula za primanje signala induktivne mjerne sonde, modula za USB prihvat i modula za napajanje [14]. Sučelje je moguće učvrstiti na aluminijski okvir robotske ćelije. Podatke je na ovaj način moguće dohvaćati pomoću Mahr Cockpit softverskog paketa i koristiti ih u aplikaciji za statističku kontrolu procesa.

5.6.4. Potprogram robota za postavljanje vijaka u napravu

Postojeća automatizacija radnog mjesta je programirana za izmjenu obradaka te je potreban potprogram koji će dodati potrebne naredbe za gibanje robota za postavljanje obratka u napravu za mjerenje. Poslije mjerenja je potrebno staviti obradak u paletni spremnik obrađenih

proizvoda. Ovaj potprogram će zamijeniti postojeći potprogram koji izuzima svaki osmi povlačni vijak na posebnu paletu za kontrolu kvalitete. Bitan zahtjev koji se postavlja na novi potprogram je da nova gibanja robota koja se uvedu ne traju duže od vremena čekanja robota u postojećem stanju radnog mjesta. Ukoliko bi trajala duže, produžilo bi se pomoćno vrijeme izmjene obradaka čime bi se smanjila produktivnost radnog mjesta.

5.6.5. Vanjsko računalo i monitor

Kao i u točki 4.3.3., posljednja komponenta je vanjsko računalo. Računalo se povezuje sa USB sučeljem mjernog sustava i automatski preuzima podatke mjerenja. Nakon toga ih obrađuje u programu i prikazuje na monitoru preko kojeg operateri dobivaju relevantne informacije i putem kojeg vrše interakciju sa sustavom. Zahtjevi koji se postavljaju na ovo računalo su mogućnost povezivanja s USB sučeljem i dovoljna memorija i procesorska snaga za pokretanje Windows 10 operativnog sustava i MS Excel programa.

6. APLIKACIJA ZA STATISTIČKU KONTROLU PROCESA


U prethodnom poglavlju su razmotrena dva predložena rješenja za automatizaciju mjerenja dimenzije i akvizicije podataka mjerenja, a iako su konceptualno različiti oba rješenja podrazumijevaju vanjsko računalo i monitor za obradu i prikaz podataka statističke kontrole podataka. Iako postoje gotova softverska rješenja za SPC, u ovom poglavlju se prikazuje aplikacija razvijena iz nule za potrebe poduzeća i radnog mjesta. Ova aplikacija je razvijena unutar programa MS Excel koristeći programski jezik Visual Basic for Applications i nazvana je SAB 4.0 – SPC.



Slika 26. Inicijalizacijski prozor aplikacije

6.1. Opseg aplikacije

Aplikacija je zamišljena kao glavno sučelje za dohvaćanje, obradu, prikaz i spremanje podataka vezanih uz mjerenje i kontrolu na radnim mjestima poduzeća. Kako će se prvo implementirati na radnom mjestu završne obrade povlačnih vijaka koje se automatizira, u radu će se prikazati aplikacija s parametrima za to radno mjesto. U dijagramu toka su prikazani svi procesi u procesu akvizicije i obrade podataka, a crtkanom plavom linijom je označeno područje unutar kojeg se nalaze procesi koje izvršava aplikacija.



Slika 27. Dijagram toka aplikacije

Početni proces je proces obrade kojim se obrađuju vijci i dobivaju se konačne dimenzije koje je potrebno mjeriti i kontrolirati. Proces mjerenja s vijcima iz završenog procesa obrade stvara mjerne podatke kao izlaz koji je ulaz za aplikaciju kroz proces dohvaćanja podataka. Osim mjernih podataka, još jedan od ulaza su unosi podataka preko korisnika koji se također koriste u aplikaciji. Potom slijedi obrada podataka koja stvara obrađene podatke kao izlaz. Ti podaci su ulaz za proces prikaza podataka i spremanja podataka. U sljedećoj tablici su pobliže pojašnjene glavne zadaće aplikacije:

Tablica 12. Glavane zadaće aplikacije

Zadaća:	Opis:
<i>Dohvaćanje</i>	Osnovna zadaća aplikacije bez koje se ne mogu obavljati ostale zadaće. Dohvaćanje podataka se obavlja pomoću fizičke veze sa strojem ili mjernom sondom pomoću RS232 ili USB sučelja, a dohvaćeni podaci se spremaju na odgovarajuće mjesto u aplikaciji. Unosi korisnika se također dohvaćaju preko korisničkog sučelja aplikacije.
<i>Obrada</i>	Pomoću programiranih algoritama aplikacije obrađuju se dohvaćeni podaci i stvaraju se vrijednosti potrebnih parametara za SPC analizu. Također se stvaraju potrebni grafički prikazi podataka koji služe za vizualnu kontrolu i praćenje procesa. Nakon završenog procesa stvaraju se izvještaji za odjel kontrole kvalitete.
<i>Prikaz</i>	Tijekom procesa se na monitoru prikazuju relevantni podaci operateru za lakše praćenje i upravljanje procesom.
<i>Spremanje</i>	Dohvaćeni i obrađeni podaci se na kraju i tijekom procesa spremaju zbog mogućnosti njihove uporabe u budućnosti.

6.2. Struktura Excel datoteke

Podaci koji se dohvaćaju i spremaju te parametri koji su potrebni za funkcioniranje aplikacije nalaze se na određenom mjestu unutar radnih listova Excel radne knjige. U trenutnoj verziji za automatizirano radno mjesto aplikacija se sastoji od sljedećih radnih listova:



Slika 28. Radni listovi aplikacije

Slika 25 pokazuje dio radnih listova aplikacije, a prvi od njih ima naziv „Program“ te se unutar istoga nalaze i spremaju privremeni parametri potrebni za cijelu aplikaciju. Pored su radni

listovi pojedinih vijaka, unutar kojih se nalaze parametri pojedinih vijaka, a u iste radne listove se zapisuju i podaci o mjerenju istih kada se obrađuju na stroju. Svaki vijak u aplikaciji je opisan sljedećim parametrima:

Tablica 13. Parametri pojedinih vijaka unutar radnog lista

Parametar: Opis:

<i>Naziv:</i>	Opis mjerene vrijednosti s tolerancijama
<i>Raspon:</i>	Parametar koji opisuje raspon kontrolne karte koja se generira.
<i>LSL:</i>	Donja granica tolerancije vijka
<i>USL:</i>	Gornja granica tolerancije vijka

Tijekom odvijanja procesa obrade aktivan je onaj radni list od onog vijka koji se obrađuje na stroju, te se u isti zapisuju dobiveni podaci sa mjerne sonde. Spremljeni podaci se koriste za prikaz SPC podataka u prozoru aplikacije i za izradu izvještaja nakon završetka procesa. Primjer podataka spremljenih u mjernom listu tijekom jednog procesa obrade:

Datum:	Nalog:	Operater:	Komentar:
04/06/2019 19:36	184920	Dino	2. smjena
i	x:	MR:	x_Bar: 26,051
1	26,053	#VALUE!	sigma 0,00157
2	26,051	-0,002	R_bar -0,00013
3	26,055	0,004	UCL: 26,056
4	26,051	-0,004	LCL: 26,046
5	26,051	0	UCL_mr: -0,00041
6	26,051	0	
7	26,052	0,001	T 0,021
8	26,053	0,001	USL: 26,06
9	26,051	-0,002	LSL: 26,039
10	26,053	0,002	
11	26,053	0	Cp 2,233032
12	26,052	-0,001	Cpu 1,905521
13	26,051	-0,001	Cpl 2,560543
14	26,05	-0,001	Cpk 1,905521
15	26,05	0	
16	26,049	-0,001	
17	26,051	0,002	
18	26,049	-0,002	
19	26,049	0	
20	26,051	0,002	
21	26,05	-0,001	
22	26,048	-0,002	
23	26,051	0,003	
24	26,051	0	
25	26,05	-0,001	

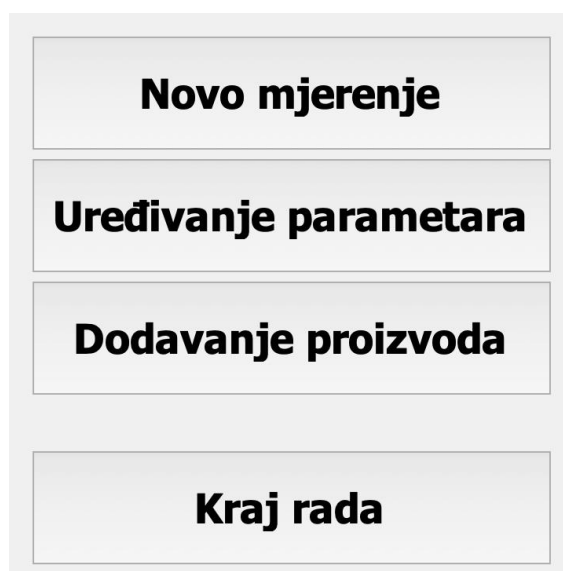
Slika 29. Mjerni list aplikacije po završetku mjerenja

Mjerni list na vrhu sadrži informacije o datumu i vremenu početka procesa obrade, broju naloga, operateru i dodatni komentar. Prvi stupac sadrži redni broj obrađenog vijka, zatim stupac do toga sadrži izmjerene vrijednosti, a predzadnji stupac sadrži kretajuće raspone. Ta tri stupca se

popunjavaju kako teče proces obrade i kako se dohvaćaju novi podaci s mjerne sonde. Pomoću podataka iz tih stupaca se u posljednjem stupcu računaju potrebne vrijednosti za kontrolne karte i za informacije o sposobnosti samog procesa pomoću izraza pojašnjenih u točkama 3.3 i 5.4. Završetkom procesa ovakav mjerni list ostaje unutar radnog lista vijka koji se je obrađivao i može se lako dohvatiti za daljnju analizu procesu.

6.3. Korisničko sučelje

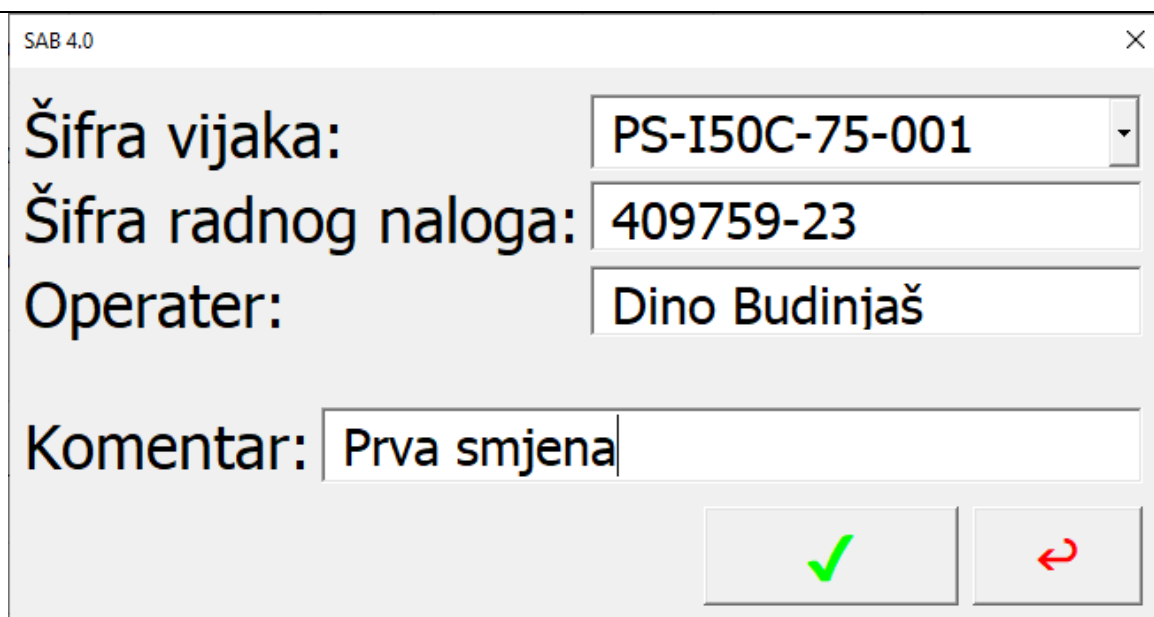
Snalaženje u brojnim radnim listovima koji su uz to i različitih veličina može biti komplicirano, a isto tako bi bilo nepraktično pratiti proces na način da operater mora crtati potrebne kontrolne karte i tražiti potrebne informacije o procesu unutar radnih listova. Stoga je osmišljeno i razvijeno jednostavno korisničko sučelje koje operaterima nudi mogućnost praćenja procesa u tijeku, izmjenu postojećih parametara vijaka i dodavanje novih vijaka u aplikaciju. Početni prozor aplikacije nudi nekoliko opcija:



Slika 30. Početni prozor aplikacije

6.3.1. Novo mjerenje

Opcija novo mjerenje otvara novi prozor u kojemu se odabire vijak koji će se obrađivati i upisuju se podaci koji će se nalaziti na vrhu mjerne liste, odnosno podaci o broju radnog naloga, o operateru, a postoji i mogućnost dodavanja dodatnog komentara. Za nastavak na sljedeći prozor potrebno je popuniti polja odabira vijka, broja radnog naloga i operatera, dok je komentar moguće izostaviti. U nastavku se otvara novi prozor koji je ostaje otvoren za vrijeme trajanja procesa obrade jer se u tom prozoru prikazuje X/MR kontrolna karta i druge relevantne informacije za praćenje procesa.



SAB 4.0

Šifra vijaka: PS-I50C-75-001

Šifra radnog naloga: 409759-23

Operater: Dino Budinjaš

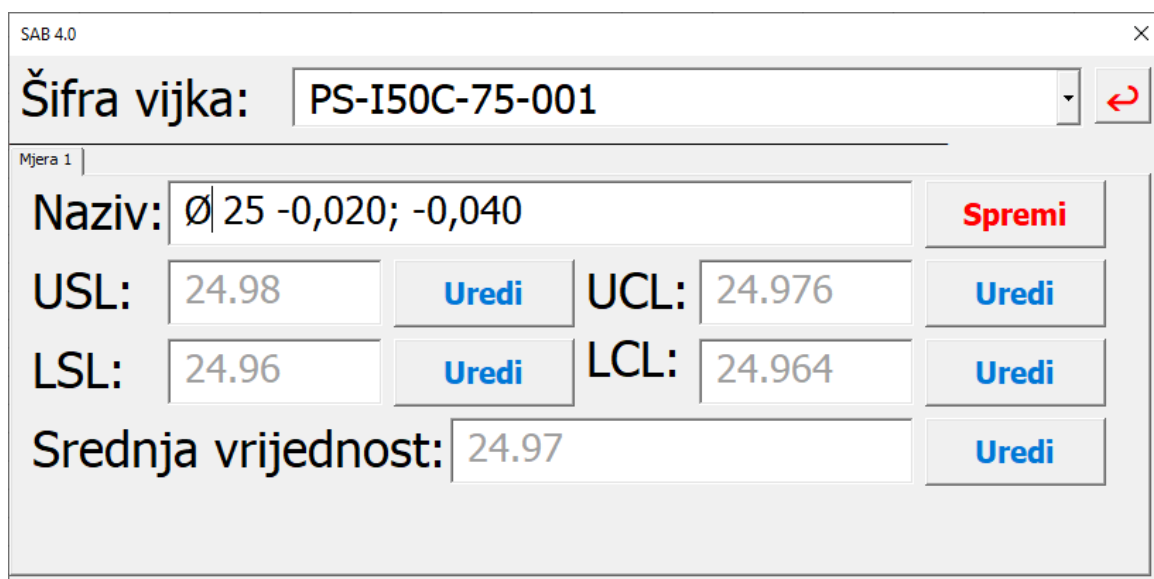
Komentar: Prva smjena

Buttons: ✓ (green), ↶ (red)

Slika 31. Prozor za unos podataka za novo mjerenje

6.3.2. Uređivanje parametara

Parametre opisane u tablici 13 za vijke koji se već nalaze u aplikaciji moguće je uređivati pomoću druge opcije kojoj se pristupa iz početnog prozora. Parametri se uređuju u novom prozoru koji se otvara i unutar kojega je potrebno odabrati vijak koji se želi uređivati pomoću padajućeg izbornika. Tada se prikazuju trenutne vrijednosti parametara vijka koje je moguće uređivati, a pritiskom na tipku „spremi“ nove vrijednosti se automatski spremaju na za to predviđena mjesta unutar radnog lista tog vijka.



SAB 4.0

Šifra vijaka: PS-I50C-75-001

Mjera 1

Naziv:	Ø 25 -0,020; -0,040	Spremi
USL:	24.98	Uredi
UCL:	24.976	Uredi
LSL:	24.96	Uredi
LCL:	24.964	Uredi
Srednja vrijednost:	24.97	Uredi

Slika 32. Prozor za uređivanje parametara vijaka

6.3.3. Dodavanje proizvoda

Posljednja opcija koju je moguće odabrati unutar početnog prozora aplikacije služi za dodavanje novih vijaka i njihovih pripadajućih parametara u aplikaciju. Potrebno je unijeti naziv novog vijka, opis mjere čija vrijednost se prati, gornju i donju granicu tolerancije i raspon koji se koristi za kontrolne karte. Aplikacija na osnovu tih vrijednosti stvara novi radni list s nazivom novog vijka i unutar radnog lista upisuje parametre prema već pojašnjennoj strukturi.



SAB 4.0

Šifra vijka:	KL-8850-RS/900
Naziv:	Ø26,06 0,000; -0,021
USL:	26,060
LSL:	06,039
UCL:	26,055
LCL:	26,045
Srednja vrijednost:	26,051

Novi vijak uspješno spremljen!

✓ ↶

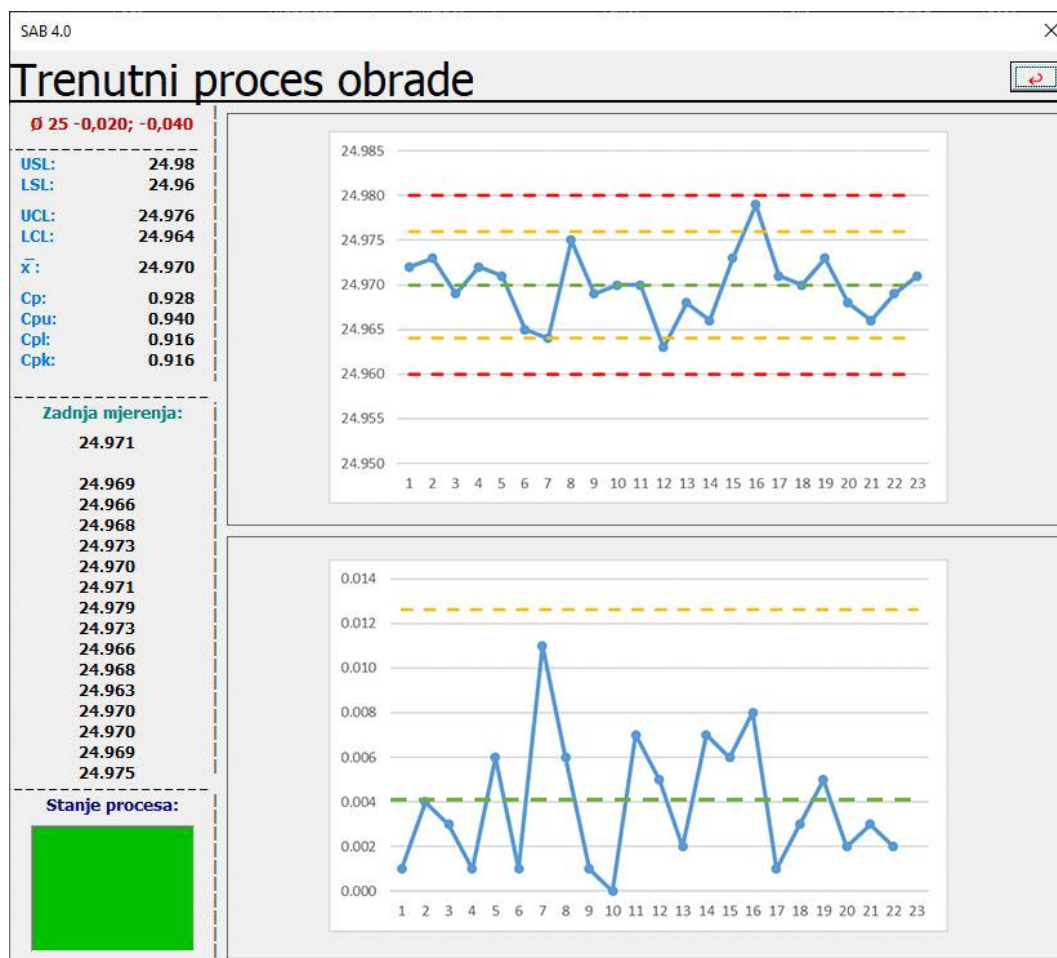
Slika 33. Prozor za dodavanje novog vijka

6.4. Korištenje aplikacije

Aplikacija se koristi cijelo vrijeme dok je automatizirano radno mjesto u uporabi. Tijekom pripreme radnog mjesta za novu seriju vijaka u aplikaciji se odabire opcija „novo mjerenje“ i operater upisuje potrebne podatke o seriji te pomoću glavnog prozora za statističku kontrolu procesa nadgleda proces obrade. Unutar tog prozora operater ima u realnom vremenu uvid u

X/MR kontrolne karte, iznose indeksa sposobnosti procesa i vrijednosti posljednjih mjerenja.

Primjer izgleda prozora tijekom procesa obrade:



Slika 34. Glavni prozor aplikacije za praćenje proizvodnje

Kako je prikazano na slici 32., ovim prozorom operater ima jednostavan pristup svim informacijama o stanju procesa obrade. U gornjem lijevom kutu prozora označena je mjera D2 s pripadajućom tolerancijom koja se automatski mjeri i pomoću koje se obavlja statistička kontrola procesa. Ispod su informacije o gornjoj i donjoj toleranciji, o gornjoj i donjoj kontrolnoj granici, o aritmetičkoj sredini procesa, te indeksi sposobnosti procesa. Također je moguće vidjeti vrijednosti zadnjih mjerenja, od kojih je najnovije vizualno odvojeno od prethodnih mjerenja. U donjem lijevom kutu nalazi se semafor stanja procesa koji ovisno o prethodno izmjerenoj vrijednosti vijka pokazuje tri stanja procesa:

- Zelena boja: izmjerena vrijednost se nalazi unutar kontrolnih granica
- Žuta boja: izmjerena vrijednost se nalazi između kontrolnih granica i granica tolerancije
- Crvena boja: izmjerena vrijednost se nalazi izvan granica tolerancije

Intervencija operatera se zahtijeva ukoliko se uoči da semafor pokazuje žutu ili crvenu boju. Najveći dio prozora ipak zauzimaju kontrolne karte. Na gornjoj polovici prozora se nalazi X kontrolna karta koja se automatski generira pomoću podataka dohvaćenih s mjerne sonde. Plavom bojom i točkama su prikazane vrijednosti individualnih mjerenja vijaka, a uspoređuju se s ostalim linijama na karti. Ostale linije su granice tolerancije (crvena boja), kontrolne granice (žuta boja) i središnja linija (zelena boja). Ispod X karte nalazi se MR karta, odnosno karta kretajućih raspona između individualnih mjerenja. Isto kao na X karti, plavom bojom su označeni individualni rasponi, zelenom bojom je naznačena središnja linija, a žutom bojom je prikazana kontrolna granica.

6.5. Programski kod aplikacije

Praćenje procesa u stvarnom vremenu pomoću grafičkog sučelja prikazanog u prethodnoj točki omogućava programski kod jezika Visual Basic for Applications koji se izvršava u pozadini. U radu je korišten ovaj programski jezik za razvoj aplikacije jer se kroz MS Excel mogu spremati i obrađivati podaci te stvarati kontrolne karte, dok VBA omogućava grafičko sučelje i programsku logiku za automatiziranje izvođenja potrebnih računanja i stvaranja kontrolnih karata. U nastavku su prikazani primjeri programskog koda za izvođenje nekih radnji:

```

Private Sub UserForm_Initialize()
Worksheets("Program").Activate
Worksheets("Program").Select
ComboBox1.RowSource = "B4:B20"
End Sub
Private Sub ComboBox1_Change()
Worksheets("Program").Range("N4") = ComboBox1.Value
End Sub
Private Sub CommandButton1_Click()

    If ComboBox1.ListIndex = -1 Or TextBox1.Value = "" Or TextBox2.Value = "" Then
MsgBox "Unesite sve tražene vrijednosti!"
Else
Dim i As String
i = Worksheets("Program").Range("N4").Value
Worksheets(i).Activate
Worksheets(i).Select
ActiveSheet.Cells(4, Columns.Count).End(xlToLeft).Select
ActiveCell.Offset(0, 6).Select
ActiveCell.Value = Now
ActiveCell.Offset(0, 1).Select
ActiveCell.Value = TextBox1.Value
ActiveCell.Offset(0, 1).Select
ActiveCell.Value = TextBox2.Value
ActiveCell.Offset(0, 1).Select
If TextBox3.Value = "" Then
ActiveCell.Value = "-"
Else
ActiveCell.Value = TextBox3.Value
End If
Novo_mjerenje.Hide
Praćenje_procesa.Show
End If

End Sub
Private Sub CommandButton2_Click()
Novo_mjerenje.Hide
Početni_zaslون.Show
End Sub

```

Dohvaćanje podataka o dostupnim vijcima

Zapisivanje odabrane vrijednosti u padajućem izborniku

Provjera jesu li upisani potrebni podaci, zapisivanje unesenih podataka u radni list odabranog vijka, otvaranje sljedećeg prozora

Povratak u prethodni prozor

Slika 35. Programski kod postavljanja novog procesa

Programski kod sa prethodne slike pokazuje pozadinu prozora sa slike 29. Programski kod prvo dohvaća podatke o dostupnim vijcima iz radnog lista „Program“, a nakon što operater unese potrebne podatke provjerava jesu li uneseni svi potrebni podaci. Ako je sve potrebno uneseno, ti se podaci zapisuju u radni list odabranog vijka i otvara se glavni prozor za praćenje proizvodnje.

7. USPOREDBA POSTOJEĆEG I PREDLOŽENOG RJEŠENJA

Postojeće radno mjesto je nedavno automatizirano s ciljem korištenja svih prednosti koje donosi robotski sustav, točnije s ciljem povećanja produktivnosti radnog mjesta uz manje operativne troškove. Povod za takvo razmišljanje su između ostalog i porast cijene radne snage, zahtjevi za bržim rokovima isporuke, a na kraju i općeniti pad cijene robotskih rješenja. Analizom isplativosti investicije utvrđeno je da postoji značajan prostor za unaprjeđenje radnog mjesta njegovom automatizacijom, stoga je taj projekt i realiziran. U točki 2.3 uspoređeno je radno mjesto prije automatizacije i sada kada je automatizirano. Iz dobivenih rezultata je vidljivo da je projekt donio pretpostavljene prednosti. Tako je prosječni broj proizvedenih vijaka po smjeni poslije automatizacije porastao za 26,82 %, a pomoćno vrijeme je smanjeno za 290 %. No i dalje je prisutan veliki broj potrebnih intervencija operatera u procesu kontrole kvalitete, što smanjuje produktivnost operatera na drugim radnim mjestima. Osim toga, na ovom radnu mjestu je očita prilika za uvođenje alata statističke kontrole procesa čime bi se dodatno osigurala kvaliteta procesa i omogućila jednostavnije upravljanje procesom. Drugim riječima ovim radom je predložena daljnja automatizacija radnog mjesta, a rješenje je ponuđeno u prethodnim poglavljima. U nastavku je uspoređeno postojeće radno mjesto nakon robotizacije s izloženim rješenjem u ovom radu preko ključnih pokazatelja performansi procesa.

7.1. Odabir pokazatelja

Direktne uštede koje se postižu uvođenjem SPC sustava i njegovom potpunom automatizacijom teško je pretpostaviti. Razlog tome leži u činjenici da je rješenje izloženo u ovom radu predloženo, a ne i implementirano, što za posljedicu ima da je nemoguće izmjeriti pokazatelje novo implementiranog sustava. Stoga će se pokušati pretpostaviti iznosi određenih pokazatelja kako bi se dobila predodžba o uštedama i prednostima koje novo rješenje donosi. Za tu svrhu je prvo potrebno odrediti pokazatelje pomoću kojih će se uspoređivati postojeće i predloženo rješenje:

- Vrijeme kontrole kvalitete operatera
- Informiranost o procesu
- Udio kontroliranih proizvoda
- Iskorištenost robota

Kod svakog od ovih pokazatelja se prikazuje usporedna tablica gdje se uspoređuju vrijednosti pokazatelja između postojećeg stanja te predloženog rješenja mjerenjem unutar stroja (u daljnjem tekstu „Rješenje 1“) i predloženog rješenja mjerenjem izvan stroja (u daljnjem tekstu „Rješenje 2“).


7.2. Vrijeme intervencije operatera

Ustanovljeno je da postojeće rješenje i dalje iziskuje određeni dio vremena operatera za obavljanje radnji kontrole kvalitete. Točnije operater trenutno kontrolira svaki osmi vijak u procesu za što potroši otprilike jednu minutu. Unutar tog vremena operater dolazi do radnog mjesta, izuzima vijak za mjerenje, vrši radnje mjerenja dva promjera i dvije duljine, zapisuje vrijednosti, te stavlja vijak nazad na paletu. Predloženim rješenjem se sve ove radnje operatera eliminiraju i zamjenjuju se sustavom za automatsko mjerenje i akviziciju podataka koji je opisan u prethodnim poglavljima. S novim rješenjem na radnom mjestu operater može vrlo lako ustanoviti je li proces u stanju statističke kontrole pogledom na semafor koji se prikazuje na monitoru pomoću SPC aplikacije. Tako su intervencije operatera svedene samo na radnje koje je potrebno provesti kada se proces nađe izvan stanja kontrole. Pretpostavljeno vrijeme kontrole kvalitete operatera je stoga nula.

Tablica 14. Usporedba postojećeg i predloženog rješenja u vremenu intervencije operatera

	Postojeće stanje	Rješenje 1	Rješenje 2
<i>Automatizirano mjerenje dimenzija</i>	NE	DA	DA
<i>Intervencija operatera za kontrolu kvalitete</i>	DA	NE	NE
<i>Vrijeme operatera za kontrolu kvalitete</i>	~ 1 min.	0 min	0 min
<i>Vrijeme operatera za kontrolu kvalitete tijekom smjene (331 kom/smj, kontrola svaki 8. komad)</i>	~ 41 min.	0 min	0 min
<i>Ušteda vremena operatera tijekom smjene:</i>	0 min.	~ 41 min.	~ 41 min.

Korištenjem sustava automatskog mjerenja i statističke kontrole procesa stvaraju se vremenske uštede za operatera u prosječnom iznosu od 41 minute. To vrijeme operater koristi na drugom radnom mjestu gdje se na taj način povećava iskorištenost radnog mjesta.



Slika 36. Uštedeno vrijeme operatera implementacijom predloženih rješenja

7.3. Informiranost o procesu

Kod trenutnog načina obavljanja kontrole kvalitete na radnom mjestu informacije se zapisuju na X kontrolnu kartu s proizvoljno određenim kontrolnim granicama. Takav način kontrole procesa je vrlo ograničen jer podaci o izmjerenim vrijednostima nisu digitalizirani, imaju malu rezoluciju (mjerenje svakog osmog vijka), ne omogućuju dinamično postavljanje kontrolnih granica i zahtijevaju intervenciju operateru u vidu njihovog unošenja na kartu. Uz to, na taj način se ne računaju indeksi sposobnosti procesa pojašnjeni u poglavlju 3.3. Predloženo rješenje omogućava akviziciju podataka pomoću mjerne sonde čime su podaci automatski digitalizirani dok se daljnje pohranjivanje, obrada i vizualizacija istih vrši pomoću aplikacije opisane u poglavlju 6. Novim rješenjem se dobiva puno više informacija o procesu koji su prezentirani i numerički i vizualno.

Tablica 15. Usporedba postojećeg i predloženog rješenja prema informiranosti o procesu

	Postojeće stanje	Rješenje 1	Rješenje 2
<i>Računalna obrada podataka</i>	NE	DA	DA
<i>Računalno spremanje podataka</i>	NE	DA	DA
<i>Prikaz podataka o procesu putem računalne aplikacije</i>	NE	DA	DA
<i>Korištenje alata statističke kontrole procesa</i>	NE	DA	DA
<i>Prikaz X/MR kontrolne karte u stvarnom vremenu</i>	NE	DA	DA
<i>Prikaz indeksa sposobnosti procesa u stvarnom vremenu</i>	NE	DA	DA
<i>Praćenje stanja procesa pomoću semafora</i>	NE	DA	DA

S aplikacijom i računalom te automatski prikupljenim podacima puno su veće mogućnosti povećanja informiranosti o procesu.


7.4. Udio kontroliranih proizvoda

Kako je opisano u poglavlju 2.2, na postojećem radnom mjestu operateri kontroliraju svaki osmi vijak, što je određeno heuristički kao povoljan omjer između potrošenog vremena operatera za intervenciju kontrole kvalitete i udjela nesukladnih obradaka. Ukoliko je mjereni vijak sukladan zahtijevanim tolerancijama, prihvaća se da je prethodnih sedam vijaka sukladno. Novim rješenjem moguće je mjeriti svaki vijak, odnosno vršiti stopostotnu kontrolu serije proizvoda bez dodatnog opterećenja operatera. Stopostotna kontrola omogućuje lakše uočavanje nesukladnih proizvoda i više podataka za statističku kontrolu procesa.

Tablica 16. Usporedba postojećeg i predloženog rješenja prema udjelu kontroliranih vijaka

	Postojeće stanje	Rješenje 1	Rješenje 2
<i>Frekvencija kontrole kvalitete</i>	Svaki osmi vijak	Svaki vijak	Svaki vijak
<i>Udio kontroliranih proizvoda</i>	12,5 %	100 %	100 %
<i>Potencijalno nesukladnih proizvoda između kontrole kvalitete</i>	8 ili manje	1	1

Povećanjem udjela kontroliranih proizvoda ostvaruju se direktne financijske uštede smanjenjem broja nesukladnih proizvoda u procesu obrade.



Slika 37. Povećanje udjela kontroliranih proizvoda



Slika 38. Smanjenje potencijalno nesukladnih proizvoda

7.5. Iskorištenost robota

Drugo predloženo rješenje kojim se vijci mjere izvan alatnog stroja na napravi unutar robotske ćelije dodatno iskorištavaju robotsko vrijeme. Naime na postojećem radnom mjestu nakon izmjene obradaka i odlaganja gotovih proizvoda na paletni spremnik, robot čeka završetak obrade novog vijka kako bi započeo novi ciklus izmjene. Implementacijom drugog predloženog rješenja za automatsku kontrolu kvalitete iskoristilo bi se vrijeme gdje robot trenutno čeka i time bi se podigla razina iskorištenja robota. Osim toga dolazi i do povećanja produktivnosti radnog mjesta jer dodatna iskorištenost robota i stopostotna kontrola kvalitete olakšavaju upravljanje procesom te smanjuju broj intervencija operatera uslijed nesukladnih proizvoda zbog bolje kontrole procesa. Iako se u Rješenju 1 koristeći mjernu sondu na stroju sam ciklus obrade produžuje, dugoročno to produljenje radi automatskog mjerenja i akvizicije podataka donosi bitne informacije o procesu i smanjuje potrebu za redovnim intervencijama operatera pa tako omogućuje rast produktivnosti kroz poboljšanje procesa i veću automatizaciju.

Tablica 17. Usporedba postojećeg i predloženog rješenja prema iskorištenju robota

	Postojeće stanje	Rješenje 1	Rješenje 2
<i>Postojanje vremena čekanja robota</i>	DA	DA	NE
<i>Povećana produktivnost radnog mjesta</i>	NE	DA	DA

8. ZAKLJUČAK

Četvrta industrijska revolucija je već u punom zamahu i mijenja svakodnevni način života ljudi širom svijeta. Najveći fokus se danas stavlja na kupca, bilo da se radi o proizvodnim ili uslužnim industrijama, a sve to omogućavaju nove tehnologije i koncepti kao što su Cyber-Physical Systems, Internet of Things, Big Data i drugi. Pomoću navedenih tehnologija kroz proces nove industrijske revolucije obične tvornice se transformiraju u pametne tvornice koje su produktivnije, efikasnije i fleksibilnije kako bi proizvodna poduzeća zadovoljila nove zahtjeve tržišta.

S obzirom na važnost transformiranja postojeće proizvodnje u pametnu proizvodnju analizirana je mogućnost potpune automatizacije robotiziranog radnog mjesta za proizvodnju povlačnih vijaka proizvodnog poduzeća SAB d.o.o. Radno mjesto je nedavno robotizirano čime je ostvarena predviđena prednost u vidu povećanja produktivnosti radnog mjesta, ali i oslobađanja radnog mjesta od operatera koji za to vrijeme obavljaju posao na drugim radnim mjestima. Unatoč tome i dalje postoji značajna potreba za intervencijom operatera za izvođenje radnji kontrole kvalitete što oduzima vrijeme operatera na drugim radnim mjestima i ne omogućava provođenje stopostotne kontrole proizvoda. Osim toga, trenutno praćenje procesa na radnom mjestu se svodi na bilježenje vrijednosti mjerenja obrađenih površina vijka na kontrolnu kartu, što zauzvrat iziskuje unošenje tih podataka u računalo, obradu tih podataka i dobivanje informacija o procesu tek nakon završetka procesa.

Predložena su dva rješenja koja omogućavaju potpunu automatizaciju radnog mjesta. Prvo rješenje koristi mjernu sondu koja se već koristi u postojećem procesu obrade, a pomoću koje se može izvoditi mjerenje vijaka i akvizicija podataka te donošenje odluke o sukladnosti proizvoda. Drugo rješenje iskorištava vrijeme čekanja robota te koristi predloženu napravu i mjernu sondu za izvođenje mjerenja sukladnosti vijka. Oba predložena rješenja koriste razvijenu aplikaciju za dohvaćanje podataka, obradu i prikaz informacija kao što su vrijednosti mjerenja, indeksi sposobnosti procesa i kontrolne karte operaterima odgovornim za to radno mjesto. Krajnji rezultat je potpuna automatizacija procesa kontrole kvalitete i prikaz stanja procesa u trenutnom vremenu.

Implementacijom predloženih rješenja za potpunu automatizaciju postižu se višestruke prednosti za poduzeće. Prije svega eliminira se redovno potrebna intervencija operatera za

obavljanje kontrole kvalitete na radnom mjestu jer te radnje obavljaju mjerne sonde automatski, a operateri mogu to vrijeme iskoristiti na drugim radnim mjestima. Korištenjem mjernih sondi za kontrolu kvalitete automatski se dohvaćaju digitalni podaci koji se spremaju unutar razvijene aplikacije, gdje se u trenutnom vremenu obrađuju i stvaraju bitne informacije o procesu koje su dostupne donosiocima odluka za radno mjesto. Isto tako, korištenjem mjernih sondi omogućava se stopostotna kontrola kvalitete proizvoda, čime se povećava kvaliteta samog procesa i dobiva se bolji uvid u stanje procesa. Na kraju, implementacijom rješenja koje podrazumijeva mjerenje vijaka izvan prostora stroja iskorištava se prazan hod robota, što znači da se tim putem ostvaruju sve prednosti potpune automatizacije bez produljenja ciklusa obrade kao što je slučaj u korištenju mjerne sonde koja se već koristi u procesu.

Predložena rješenja pokazuju da itekako postoji mogućnost potpune automatizacije radnog mjesta odnosno da je prirodan korak dalje u unaprjeđenju radnog mjesta, a time i proizvodnje. Promatrano radno mjesto je prvo radno mjesto poduzeća SAB d.o.o. koje je robotizirano što je još oznaka treće industrijske revolucije, a implementacijom rješenja predloženog u radu koje uključuje automatizaciju kontrole kvalitete, povezivanje različitih sustava te korištenje te korištenje statističke obrade podataka za donošenje odluka o procesu pruža poduzeću mali, ali bitan iskorak u smjeru četvrte industrijske revolucije i transformacije u pametnu tvornicu budućnosti.

LITERATURA

- [1] N. Jazdi, "Cyber physical systems in the context of Industry 4.0," *2014 IEEE International Conference on Automation, Quality and Testing, Robotics*, Cluj-Napoca
- [2] Lidong Wang, Guanghui Wang, "Big Data in Cyber-Physical Systems, Digital Manufacturing and Industry 4.0", *International Journal of Engineering and Manufacturing(IJEM)*, Vol.6, No.4
- [3] Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., & Hoffmann, M. (2014). *Industry 4.0. Business & Information Systems Engineering*
- [4] Budinjaš, Dino (2018) - Usporedba postojećeg radnog mjesta s budućim predloženim automatiziranim rješenjem, završni rad, Fakultet Strojarnstva i Brodogradnje
- [5] Staphenurst T. (2005) – *Mastering Statistical Process Control*, Elsevier Butterworth-Heinemann, str. 3,15
- [6] John S. Oakland (2003) - *Statistical Process Control*, Butterworth-Heinemann, str. 260, 264
- [7] dr. sc. Biserka Runje – materijali iz kolegija Osnove osiguranja kvalitete
- [8] Montgomery, D., *Introduction to Statistical Quality Control*
- [9] doc dr. sc. Hrvoje Cajner – materijali iz kolegija Inženjerska statistika
- [10] https://www.researchgate.net/figure/The-confidence-intervals-correspond-to-3-sigma-rule-of-the-normal-distribution_fig3_273955667 (pristupljeno 20.3.2019.)
- [11] <https://www.marposs.com/eng/product/compact-optical-transmission-probe> (pristupljeno 25.5.2019.)
- [12] <https://new.abb.com/products/robotics/industrial-robots/irb-1200> (pristupljeno 26.5.2019.)
- [13] <https://www.mahr.com/en-gb/Services/Production-metrology/Products/Millimar---Electrical-Length-Measuring-Instruments-and-Multi-Gaging-Metrology/Millimar---Inductive-probe/Millimar-P2000---Inductive-probe/Millimar-P2004---Inductive-probe/Millimar-P2004---Inductive-probe/> (pristupljeno 27.5.2019.)
- [14] <https://www.mahr.com/en-gb/Services/Production-metrology/Products/Millimar---Electrical-Length-Measuring-Instruments-and-Multi-Gaging-Metrology/Millimar---Indication-and-evaluation-instruments/Millimar-N-1700---Modular-bus-system/Millimar-N-1702---Modules-for-inductive-probes/> (pristupljeno 27.5.2019.)

- [15] <https://tacrockford.com/product/tool-holder-taper-complete-measuring-units/>
(pristupljeno 12.6.2019.)
- [16] Montgomery, Douglas (2004), *Introduction to Statistical Quality Control*, New York, New York: John Wiley & Sons Inc, str. 776

PRILOZI

- I. CD disk
- II. Prikupljeni mjerni podaci
- III. Programski kod za mjernu sondu
- IV. Programski kod MS Excel aplikacije

Prikupljeni mjerni podaci

Vijak:	Mjera 1:	Mjera 2:	Vijak:	Mjera 1:	Mjera 2:
1	26.053	28.954	57	26.052	28.953
2	26.051	28.952	58	26.055	28.953
3	26.055	28.958	59	26.056	28.955
4	26.051	28.955	60	26.052	28.952
5	26.051	28.953	61	26.056	28.957
6	26.051	28.952	62	26.053	28.952
7	26.052	28.956	63	26.057	28.956
8	26.053	28.953	64	26.056	28.956
9	26.051	28.952	65	26.048	28.948
10	26.053	28.954	66	26.048	28.946
11	26.053	28.953	67	26.058	28.958
12	26.052	28.95	68	26.048	28.949
13	26.051	28.951	69	26.049	28.949
14	26.05	28.949	70	26.048	28.947
15	26.05	28.951	71	26.05	28.95
16	26.049	28.947	72	26.049	28.947
17	26.051	28.952	73	26.049	28.949
18	26.049	28.95	74	26.05	28.949
19	26.049	28.95	75	26.052	28.952
20	26.051	28.951	76	26.051	28.951
21	26.05	28.95	77	26.05	28.951
22	26.048	28.946	78	26.05	28.949
23	26.051	28.952	79	26.051	28.951
24	26.051	28.951	80	26.05	28.951
25	26.05	28.949	81	26.05	28.951
26	26.05	28.95	82	26.051	28.949
27	26.049	28.949	83	26.051	28.95
28	26.05	28.949	84	26.053	28.95
29	26.05	28.952	85	26.056	28.955
30	26.049	28.95	86	26.055	28.954
31	26.05	28.951	87	26.053	28.951
32	26.049	28.95	88	26.054	28.955
33	26.048	28.949	89	26.049	28.95
34	26.053	28.952	90	26.049	28.951
35	26.05	28.951	91	26.05	28.95
36	26.054	28.955	92	26.057	28.955
37	26.05	28.955	93	26.051	28.951
38	26.051	28.951	94	26.047	28.945
39	26.051	28.951	95	26.047	28.948
40	26.051	28.952	96	26.049	28.949
41	26.051	28.951	97	26.047	28.947
42	26.052	28.952	98	26.048	28.947
43	26.051	28.95	99	26.047	28.947
44	26.052	28.952	100	26.05	28.951
45	26.051	28.949	101	26.049	28.953
46	26.049	28.947	102	26.048	28.947
47	26.051	28.952	103	26.049	28.949
48	26.054	28.952	104	26.049	28.95
49	26.053	28.953	105	26.049	28.949
50	26.052	28.951	106	26.049	28.951
51	26.054	28.952	107	26.049	28.951
52	26.05	28.948	108	26.05	28.951
53	26.054	28.952	109	26.049	28.949
54	26.052	28.952	110	26.05	28.952
55	26.055	28.952	111	26.052	28.954
56	26.058	28.957	112	26.051	28.952

Programski kod za mjernu sondu

```
N111;
T0830 (SONDA);
G0 X50 Z-5;
#140 =28;
#141 =-5;
#142 =-0.02;
#143 =-0.04;
M98 P9060;
M5;
M30;
%

09060
#119 =1000;
G0 M9;
M5 G40;
T0830;
M58;
G58;
G98;
#124 =#5041;
#125 =#5042;
G4 X0.5;
G0 Z#141;
#145 =#140+1;
#146 =#140-1;
G31 X[#140+1] F#119;
G04 X0.1;
IF[#145 EQ #5041] GOT010;
N10;
G31 U-2 F50;
G4 X0.1;
IF[#146 EQ #5041] GOT020;
#150 =#5041;
#999 =#5041;
G1 U5 F2000;
G0 X200;
#148 =[#140+#142];
#149 =[#140+#143];
IF[#150 GT #148] GOT099;
IF[#150 LT #149] GOT099;
G99;
M59;
M99:
N20;
#3000 =1;
N99 #3000 =1;
M99
%
```

Programski kod MS Excel aplikacije

Inicijalizacija aplikacije

```
Private Sub Workbook_Open()  
  
ActiveWindow.WindowState = xlMinimized  
Sheets("Program").Select  
Worksheets("Program").Range("N4").ClearContents  
Splash.Show '
```

```
End Sub
```

```
Private Sub UserForm_Initialize()  
    HideTitleBar Me  
End Sub
```

```
Private Sub UserForm_Activate()  
    Application.Wait (Now + TimeValue("00:00:01"))  
    Splash.Label1.Caption = "Učitavanje podataka..."  
    Splash.Repaint  
    Application.Wait (Now + TimeValue("00:00:01"))  
    Splash.Label1.Caption = "Stvaranje sučelja..."  
    Splash.Repaint  
    Application.Wait (Now + TimeValue("00:00:01"))  
    Splash.Label1.Caption = "Otvaranje..."  
    Splash.Repaint  
    Application.Wait (Now + TimeValue("00:00:01"))  
    ActiveWindow.WindowState = xlMaximized  
    Unload Splash  
    Pocetni_zaslon.Show  
End Sub
```

Početni prozor

```
Private Sub CommandButton1_Click()  
Pocetni_zaslon.Hide  
Novo_mjerenje.Show  
End Sub
```

```
Private Sub CommandButton2_Click()  
Pocetni_zaslon.Hide  
Uredivanje_parametara.Show  
End Sub
```

```
Private Sub CommandButton3_Click()  
    Pocetni_zaslon.Hide  
    Dodavanje_vijaka.Show  
End Sub
```

```
Private Sub CommandButton4_Click()  
ActiveWorkbook.Close SaveChanges:=True  
Application.Quit  
ThisWorkbook.Saved = True  
End Sub
```

Prozor „Novo mjerenje“

```
Private Sub ComboBox1_Change()  
    Worksheets("Program").Range("N4") = ComboBox1.Value  
End Sub  
Private Sub CommandButton1_Click()  
  
    If ComboBox1.ListIndex = -1 Or TextBox1.Value = "" Or TextBox2.Value = "" Then  
        MsgBox "Unesite sve tražene vrijednosti!"  
    Else  
        Dim i As String  
        i = Worksheets("Program").Range("N4").Value  
        Worksheets(i).Activate  
        Worksheets(i).Select  
        ActiveSheet.Cells(4, Columns.Count).End(xlToLeft).Select  
        ActiveCell.Offset(0, 6).Select  
        ActiveCell.Value = Now  
        ActiveCell.Offset(0, 1).Select  
        ActiveCell.Value = TextBox1.Value  
        ActiveCell.Offset(0, 1).Select  
        ActiveCell.Value = TextBox2.Value  
        ActiveCell.Offset(0, 1).Select  
        If TextBox3.Value = "" Then  
            ActiveCell.Value = "-"  
        Else  
            ActiveCell.Value = TextBox3.Value  
        End If  
        Novo_mjerenje.Hide  
        Praćenje_procesa.Show  
    End If  
  
End Sub  
Private Sub CommandButton2_Click()  
    Novo_mjerenje.Hide  
    Pocetni_zaslون.Show  
End Sub  
  
Private Sub UserForm_Initialize()  
  
    Worksheets("Program").Activate  
    Worksheets("Program").Select  
    ComboBox1.RowSource = "B4:B20"  
  
End Sub
```

Prozor „Praćenje proizvodnje“

```

Private Sub CommandButton1_Click()
ActiveSheet.Range("H14").Value = ActiveSheet.Range("H14").Value + 1
ActiveSheet.Range("K4").End(xlDown).Select
ActiveCell.Offset(1, 0).Select
If TextBox1.Value = "" Then
ActiveCell.Value = TextBox1
Else
ActiveCell.Value = TextBox1
ActiveCell = CDb1(TextBox1)
End If

Label80.Caption = Label79.Caption
Label79.Caption = Label68.Caption
Label68.Caption = Label67.Caption
Label67.Caption = Label66.Caption
Label66.Caption = ActiveSheet.Cells(5, 11).End(xlDown).Value

If ActiveSheet.Cells(5, 11).End(xlDown).Value > ActiveSheet.Range("D5").Value And ActiveSheet.Cells(5, 11).End(xlDown).Value < ActiveSheet.Range("E5").Value Then
TextBox2.BackColor = vbGreen
End If

If ActiveSheet.Cells(5, 11).End(xlDown).Value > ActiveSheet.Range("G5").Value Then
TextBox2.BackColor = vbRed
End If

If ActiveSheet.Cells(5, 11).End(xlDown).Value < ActiveSheet.Range("F5").Value Then
TextBox2.BackColor = vbRed
End If

If ActiveSheet.Cells(5, 11).End(xlDown).Value > ActiveSheet.Range("E5").Value And ActiveSheet.Cells(5, 11).End(xlDown).Value < ActiveSheet.Range("G5").Value Then
TextBox2.BackColor = vbYellow
End If

If ActiveSheet.Cells(5, 11).End(xlDown).Value < ActiveSheet.Range("D5").Value And ActiveSheet.Cells(5, 11).End(xlDown).Value > ActiveSheet.Range("F5").Value Then
TextBox2.BackColor = vbYellow
End If

ActiveSheet.Range("K5").Value = ActiveSheet.Range("K6").Value

ActiveCell.Offset(0, 1).Select

ActiveCell.Value = ActiveCell.Offset(0, -1).Value - ActiveCell.Offset(-1, -1).Value
ActiveCell.Offset(0, 1).Select
ActiveCell.Value = Abs(ActiveCell.Offset(0, -1).Value)

ActiveSheet.Range("I11").Value = Application.StDev(Range(ActiveSheet.Range("K6"), ActiveSheet.Cells(6, 11).End(xlDown)))
ActiveSheet.Range("I11").Value = WorksheetFunction.IfError(Cells(11, 9).Value, 1)

ActiveSheet.Range("I7").Value = (ActiveSheet.Range("G5").Value - ActiveSheet.Range("F5").Value) / (6 * ActiveSheet.Range("I11").Value)
Label74.Caption = ActiveSheet.Range("I7").Value

ActiveSheet.Range("I8").Value = (ActiveSheet.Range("G5").Value - ActiveSheet.Range("I4").Value) / (3 * ActiveSheet.Range("I11").Value)
Label75.Caption = ActiveSheet.Range("I8").Value

ActiveSheet.Range("I9").Value = (ActiveSheet.Range("I4").Value - ActiveSheet.Range("F5").Value) / (3 * ActiveSheet.Range("I11").Value)
Label76.Caption = ActiveSheet.Range("I9").Value

Label77.Caption = Application.Min(ActiveSheet.Range("I8", "I9"))

ActiveSheet.Range("I4").Value = Application.Average(Range(ActiveSheet.Range("K6"), ActiveSheet.Cells(6, 11).End(xlDown)))
Label73.Caption = ActiveSheet.Range("I4").Value

ActiveSheet.Range("I12").Value = Application.Average(Range(ActiveSheet.Range("M7"), ActiveSheet.Cells(7, 13).End(xlDown)))
ActiveSheet.Range("H16:H204").Value = ActiveSheet.Range("I12").Value
ActiveSheet.Range("I12").Value = WorksheetFunction.IfError(Cells(12, 9).Value, 1)

ActiveSheet.Range("I13").Value = 3.27 * ActiveSheet.Range("I12").Value
ActiveSheet.Range("J5:J204").Value = ActiveSheet.Range("I13").Value

If ActiveSheet.Range("H14").Value > 10 Then
ActiveSheet.Range("I5").Value = ((ActiveSheet.Range("I4") - (3 * ((ActiveSheet.Range("I12")) / 1.128)))
ActiveSheet.Range("I6").Value = ((ActiveSheet.Range("I4") + (3 * ((ActiveSheet.Range("I12")) / 1.128)))
End If

Image1.Enabled = True

Dim MyChart3 As Chart
Dim ChartData3 As Range
Dim chartIndex3 As Integer
Dim ChartName3 As String

Set ChartData3 = Range((ActiveSheet.Range("K6")), ActiveSheet.Cells(5, 11).End(xlDown))
Set MyChart3 = ActiveSheet.Shapes.AddChart(xlXYScatterLines).Chart

MyChart3.Axes(xlValue).MinimumScale = ActiveSheet.Range("B2")
MyChart3.Axes(xlValue).MaximumScale = ActiveSheet.Range("B3")

MyChart3.Axes(xlCategory).MinimumScale = 1
MyChart3.Axes(xlCategory).MaximumScale = ActiveSheet.Range("B" & (ActiveCell.Row))

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(1).Name = ChartName3
MyChart3.SeriesCollection(1).Values = ChartData3
MyChart3.SeriesCollection(1).XValues = ActiveSheet.Range("A6", "A" & (ActiveCell.Row))
MyChart3.Legend.Delete
MyChart3.ChartArea.Border.LineStyle = xlNone

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(2).Name = KontrolnelinijeMax
MyChart3.SeriesCollection(2).Values = ActiveSheet.Range("E5:E204")
MyChart3.SeriesCollection(2).XValues = ActiveSheet.Range("B6", "B" & (ActiveCell.Row))
MyChart3.SeriesCollection(2).MarkerBackgroundColor = xlNone
MyChart3.SeriesCollection(2).MarkerForegroundColor = RGB(255, 0, 0)
MyChart3.SeriesCollection(2).MarkerStyle = None
MyChart3.SeriesCollection(2).Border.Color = vbYellow
MyChart3.SeriesCollection(2).Border.Weight = xlThin
MyChart3.SeriesCollection(2).Border.LineStyle = xlDash

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(3).Name = KontrolnelinijeMin
MyChart3.SeriesCollection(3).Values = ActiveSheet.Range("D5:D204")

```

```

MyChart3.SeriesCollection(3).XValues = ActiveSheet.Range("B6", "B" & (ActiveCell.Row))
MyChart3.SeriesCollection(3).MarkerBackgroundColor = xlNone
MyChart3.SeriesCollection(3).MarkerForegroundColor = RGB(255, 0, 0)
MyChart3.SeriesCollection(3).MarkerStyle = None
MyChart3.SeriesCollection(3).Border.Color = vbYellow
MyChart3.SeriesCollection(3).Border.Weight = xlThin
MyChart3.SeriesCollection(3).Border.LineStyle = xlDash

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(4).Name = SrednjaVrijednost
MyChart3.SeriesCollection(4).Values = ActiveSheet.Range("C5:C204")
MyChart3.SeriesCollection(4).XValues = ActiveSheet.Range("B6", "B" & (ActiveCell.Row))
MyChart3.SeriesCollection(4).MarkerBackgroundColor = xlNone
MyChart3.SeriesCollection(4).MarkerForegroundColor = RGB(0, 255, 0)
MyChart3.SeriesCollection(4).MarkerStyle = None
MyChart3.SeriesCollection(4).Border.Color = RGB(0, 255, 0)
MyChart3.SeriesCollection(4).Border.Weight = xlThin

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(5).Name = TolerancijeMin
MyChart3.SeriesCollection(5).Values = ActiveSheet.Range("F5:F204")
MyChart3.SeriesCollection(5).XValues = ActiveSheet.Range("B6", "B" & (ActiveCell.Row))
MyChart3.SeriesCollection(5).MarkerBackgroundColor = xlNone
MyChart3.SeriesCollection(5).MarkerForegroundColor = RGB(0, 255, 0)
MyChart3.SeriesCollection(5).MarkerStyle = None
MyChart3.SeriesCollection(5).Border.Color = RGB(255, 0, 0)
MyChart3.SeriesCollection(5).Border.Weight = xlMedium

MyChart3.SeriesCollection.NewSeries
MyChart3.SeriesCollection(6).Name = TolerancijeMax
MyChart3.SeriesCollection(6).Values = ActiveSheet.Range("G5:G204")
MyChart3.SeriesCollection(6).XValues = ActiveSheet.Range("B6", "B" & (ActiveCell.Row))
MyChart3.SeriesCollection(6).MarkerBackgroundColor = xlNone
MyChart3.SeriesCollection(6).MarkerForegroundColor = RGB(0, 255, 0)
MyChart3.SeriesCollection(6).MarkerStyle = None
MyChart3.SeriesCollection(6).Border.Color = RGB(255, 0, 0)
MyChart3.SeriesCollection(6).Border.Weight = xlMedium

Dim imageName3 As String
imageName3 = Application.DefaultFilePath & Application.PathSeparator & "TempChart3.gif"

MyChart3.Export Filename:=imageName3, FilterName:="GIF"

ActiveSheet.ChartObjects().Delete
Pračenje_procesa.Imagel.Picture = LoadPicture(imageName3)

Image2.Enabled = True

Dim MyChart2 As Chart
Dim ChartData2 As Range
Dim chartIndex2 As Integer
Dim ChartName2 As String

Set ChartData2 = Range(ActiveSheet.Range("M6"), ActiveSheet.Cells(Rows.Count, 13).End(xlUp))
Set MyChart2 = ActiveSheet.Shapes.AddChart(xlXYScatterLines).Chart

MyChart2.Axes(xlValue).MinimumScale = 0

MyChart2.Axes(xlValue).MaximumScale = 0.015

MyChart2.Axes(xlCategory).MinimumScale = 1
MyChart2.Axes(xlCategory).MaximumScale = ActiveSheet.Range("B" & (ActiveCell.Row))

MyChart2.SeriesCollection.NewSeries
MyChart2.SeriesCollection(1).Name = ChartName2
MyChart2.SeriesCollection(1).Values = ChartData2
MyChart2.SeriesCollection(1).XValues = ActiveSheet.Range("A6", "A" & (ActiveCell.Row))
MyChart2.Legend.Delete
MyChart2.ChartArea.Border.LineStyle = xlNone

```



```

MyChart2.SeriesCollection.NewSeries
MyChart2.SeriesCollection(2).Name = KontrolnelinijeMax
MyChart2.SeriesCollection(2).Values = ActiveSheet.Range("J5:J204")
MyChart2.SeriesCollection(2).XValues = ActiveSheet.Range("B5", "B" & (ActiveCell.Row))
MyChart2.SeriesCollection(2).MarkerBackgroundColor = xlNone
MyChart2.SeriesCollection(2).MarkerForegroundColor = RGB(255, 0, 0)
MyChart2.SeriesCollection(2).MarkerStyle = None
MyChart2.SeriesCollection(2).Border.Color = vbYellow
MyChart2.SeriesCollection(2).Border.Weight = xlThin
MyChart2.SeriesCollection(2).Border.LineStyle = xlDash

MyChart2.SeriesCollection.NewSeries
MyChart2.SeriesCollection(4).Name = SrednjaVrijednost
MyChart2.SeriesCollection(4).Values = ActiveSheet.Range("H16:H204")
MyChart2.SeriesCollection(4).XValues = ActiveSheet.Range("B5", "B" & (ActiveCell.Row))
MyChart2.SeriesCollection(4).MarkerBackgroundColor = xlNone
MyChart2.SeriesCollection(4).MarkerForegroundColor = RGB(0, 255, 0)
MyChart2.SeriesCollection(4).MarkerStyle = None
MyChart2.SeriesCollection(4).Border.Color = RGB(0, 255, 0)
MyChart2.SeriesCollection(4).Border.Weight = xlThin

Dim imageName2 As String
imageName2 = Application.DefaultFilePath & Application.PathSeparator & "TempChart2.gif"

MyChart2.Export Filename:=imageName2, FilterName:="GIF"

ActiveSheet.ChartObjects().Delete
Pračenje_procesa.Image2.Picture = LoadPicture(imageName2)

```

End Sub

```
Private Sub CommandButton2_Click()
```

```

ActiveSheet.Cells(4, Columns.Count).End(xlToLeft).Select
ActiveSheet.Cells(Rows.Count, ActiveCell.Column).End(xlUp).Select
ActiveCell.Offset(1, -3).Select
ActiveSheet.Range("A6:A200").Copy
ActiveCell.PasteSpecial Paste:=xlPasteValues
ActiveCell.Offset(0, 1).Select
ActiveSheet.Range("K6:K500").Copy ActiveCell
ActiveCell.Offset(0, 1).Select
ActiveSheet.Range("M7:M500").Copy ActiveCell
ActiveCell.Offset(0, 1).Select
ActiveSheet.Range("H4:I13").Copy
ActiveCell.PasteSpecial Paste:=xlPasteValues

```

```

ActiveSheet.Range(ActiveCell.Offset(-1, -3), ActiveCell.Offset(200, 1)).BorderAround ColorIndex:=1, Weight:=xlThick
End Sub

```

```
Private Sub UserForm_Initialize()
```

```

Label2.Caption = ActiveSheet.Range("B1").Value
Label69.Caption = ActiveSheet.Range("G5").Value
Label170.Caption = ActiveSheet.Range("F5").Value
Label171.Caption = ActiveSheet.Range("E5").Value
Label172.Caption = ActiveSheet.Range("D5").Value

```

```

ActiveSheet.Range("K6:K500").ClearContents
ActiveSheet.Range("L6:L500").ClearContents
ActiveSheet.Range("M6:M500").ClearContents

```

```
Dim i As Integer
```

```

i = 0
ActiveSheet.Range("H14").Value = i
End Sub

```

Prozor „Uređivanje parametara“

```
Private Sub ComboBox1_Change()  
    Worksheets("Program").Activate  
    Worksheets("Program").Select  
    Worksheets("Program").Range("N4") = ComboBox1.Value  
  
    Dim i As String  
    i = Worksheets("Program").Range("N4").Value  
    Worksheets(i).Activate  
    Worksheets(i).Select  
  
    Worksheets("Program").Range("g5") = TextBox5.Value  
    Worksheets("Program").Range("f5") = TextBox6.Value  
    Worksheets("Program").Range("e5") = TextBox7.Value  
    Worksheets("Program").Range("d5") = TextBox8.Value  
    Worksheets("Program").Range("c5") = TextBox9.Value  
  
    TextBox1.Value = ActiveSheet.Range("B1")  
    TextBox5.Value = ActiveSheet.Range("G5")  
    TextBox6.Value = ActiveSheet.Range("F5")  
    TextBox7.Value = ActiveSheet.Range("E5")  
    TextBox8.Value = ActiveSheet.Range("D5")  
    TextBox9.Value = ActiveSheet.Range("C5")  
  
End Sub
```

```
Private Sub CommandButton2_Click()  
    Uredivanje_parametara.Hide  
    Pocetni_zaslona.Show  
End Sub
```

```
Private Sub CommandButton1_Click()  
    If CommandButton1.Caption = "Spremi" Then  
        TextBox1.Enabled = False  
  
        Select Case TabStrip1.Value  
  
            Case 0  
                ActiveSheet.Range("B1").Value = TextBox1.Value  
            Case 1  
                ActiveSheet.Range("C1").Value = TextBox1.Value  
            Case 2  
                ActiveSheet.Range("D1").Value = TextBox1.Value  
            Case 3  
                ActiveSheet.Range("E1").Value = TextBox1.Value  
        End Select  
  
        CommandButton1.Caption = "Uredi"  
        CommandButton1.ForeColor = vbHighlight  
  
    Else  
  
        TextBox1.Enabled = True
```

```
        CommandButton1.Caption = "Spremi"  
        CommandButton1.ForeColor = vbRed  
  
    End If  
End Sub
```

```
Private Sub CommandButton5_Click()  
    If CommandButton5.Caption = "Spremi" Then  
        TextBox5.Enabled = False  
  
        ActiveSheet.Range("G5:G204").Value = TextBox5.Value  
  
        CommandButton5.Caption = "Uredi"  
        CommandButton5.ForeColor = vbHighlight  
  
    Else  
  
        TextBox5.Enabled = True  
        CommandButton5.Caption = "Spremi"  
        CommandButton5.ForeColor = vbRed  
  
    End If  
End Sub
```

```
Private Sub CommandButton6_Click()  
    If CommandButton6.Caption = "Spremi" Then  
        TextBox6.Enabled = False  
  
        ActiveSheet.Range("F5:F204").Value = TextBox6.Value  
  
        CommandButton6.Caption = "Uredi"  
        CommandButton6.ForeColor = vbHighlight  
  
    Else  
  
        TextBox6.Enabled = True  
        CommandButton6.Caption = "Spremi"  
        CommandButton6.ForeColor = vbRed  
  
    End If  
End Sub
```

```
Private Sub CommandButton7_Click()  
    If CommandButton7.Caption = "Spremi" Then  
        TextBox7.Enabled = False  
  
        ActiveSheet.Range("E5:E204").Value = TextBox7.Value  
  
        CommandButton7.Caption = "Uredi"  
        CommandButton7.ForeColor = vbHighlight  
  
    Else  
  
        TextBox7.Enabled = True  
        CommandButton7.Caption = "Spremi"  
        CommandButton7.ForeColor = vbRed  
  
    End If  
End Sub
```

```
Private Sub CommandButton8_Click()
```

```

    If CommandButton8.Caption = "Spremi" Then
    TextBox8.Enabled = False

    ActiveSheet.Range("D5:D204").Value = TextBox8.Value

    CommandButton8.Caption = "Uredi"
    CommandButton8.ForeColor = vbHighlight

    Else

    TextBox8.Enabled = True
    CommandButton8.Caption = "Spremi"
    CommandButton8.ForeColor = vbRed

    End If
End Sub
Private Sub CommandButton9_Click()
    If CommandButton9.Caption = "Spremi" Then
    TextBox9.Enabled = False

    ActiveSheet.Range("C5:C204").Value = TextBox9.Value

    CommandButton9.Caption = "Uredi"
    CommandButton9.ForeColor = vbHighlight

    Else

    TextBox9.Enabled = True
    CommandButton9.Caption = "Spremi"
    CommandButton9.ForeColor = vbRed

    End If
End Sub
Private Sub UserForm_Activate()

    Sheets("Program").Activate
    Sheets("Program").Select
    ComboBox1.RowSource = "B4:B20"

End Sub

```

Prozor „Dodavanje vijaka“

```

Private Sub CommandButton1_Click()
    Label65.Visible = True

    ActiveWorkbook.Sheets.Add After:=Worksheets(Worksheets.Count)
    ActiveSheet.Name = TextBox1.Value

    Sheets("Novi_vijak").Range("A1:O205").Copy ActiveCell

    ActiveSheet.Range("B1").Value = TextBox2.Value
    ActiveSheet.Range("B1").Value = TextBox2.Value
    ActiveSheet.Range("G5:G204").Value = TextBox3.Value
    ActiveSheet.Range("G5:G204").Value = TextBox3.Value
    ActiveSheet.Range("F5:F204").Value = TextBox4.Value
    ActiveSheet.Range("E5:E204").Value = TextBox5.Value
    ActiveSheet.Range("D5:D204").Value = TextBox8.Value
    ActiveSheet.Range("C5:C204").Value = TextBox9.Value
    ActiveSheet.Range("B2").Value = TextBox10.Value
    ActiveSheet.Range("B3").Value = TextBox11.Value

    Sheets("Program").Cells(Rows.Count, 2).End(xlUp).Offset(1, 0).Value = TextBox1.Value

End Sub
Private Sub CommandButton2_Click()
    Dodavanje_vijaka.Hide
    Pocetni_zaslون.Show
End Sub
Private Sub Label65_Click()

End Sub

```